

**UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E
MUCURI**

Programa de Pós-Graduação em Educação

Patrick Aurélio Luiz Ribeiro

**UTILIZAÇÃO DE MÉDIA MÓVEL EXPONENCIALMENTE
PONDERADA PARA DETECTAR E CORRIGIR OS ESTILOS DE
APRENDIZAGEM DO ESTUDANTE**

Diamantina

2017

Patrick Aurélio Luiz Ribeiro

**UTILIZAÇÃO DE MÉDIA MÓVEL EXPONENCIALMENTE
PONDERADA PARA DETECTAR E CORRIGIR OS ESTILOS DE
APRENDIZAGEM DO ESTUDANTE**

Dissertação apresentada ao programa de Pós-Graduação em Educação da Universidade Federal dos Vales do Jequitinhonha e Mucuri, como requisito parcial para a obtenção do título de Mestre em Educação

Orientadora: Profa. Dra. Luciana Pereira de Assis

Coorientador: Prof. Dr. Alessandro Vivas Andrade

**Diamantina
2017**

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM
Bibliotecário Anderson César de Oliveira Silva, CRB6 – 2618.

R484u Ribeiro, Patrick Aurélio Luiz
Utilização de Média Móvel Exponencialmente Ponderada para
detectar e corrigir os Estilos de Aprendizagem do estudante / Patrick
Aurélio Luiz Ribeiro. – Diamantina, 2017.
147 p. : il.

Orientadora: Luciana Pereira de Assis
Coorientador: Alessandro Vivas Andrade

Dissertação (Mestrado Profissional – Programa de Pós-Graduação
em Educação) - Universidade Federal dos Vales do Jequitinhonha e
Mucuri.

1. Aprendizagem por Reforço. 2. Estilos de Aprendizagem.
3. Sistemas Inteligentes. 4. Média Móvel Exponencialmente
Ponderada. I. Assis, Luciana Pereira de. II. Andrade, Alessandro
Vivas. III. Título. IV. Universidade Federal dos Vales do
Jequitinhonha e Mucuri.

CDD 006.3

Elaborado com os dados fornecidos pelo(a) autor(a).

Patrick Aurélio Luiz Ribeiro

**UTILIZAÇÃO DE MÉDIA MÓVEL EXPONENCIALMENTE
PONDERADA PARA DETECTAR E CORRIGIR OS ESTILOS DE
APRENDIZAGEM DO ESTUDANTE**

Dissertação apresentada ao programa de
Pós-Graduação em Educação da Universi-
dade Federal dos Vales do Jequitinhonha e
Mucuri, como requisito parcial para a ob-
tenção do título de Mestre em Educação

Orientadora: Profa. Dra. Luciana Pereira de
Assis

Coorientador: Prof. Dr. Alessandro Vivas
Andrade

Data de aprovação: 28/09/2017

Profa. Dra. Luciana Pereira de Assis
Orientadora

Prof. Dr. Alessandro Vivas Andrade
Coorientador

Profa. Dra. Adriana Nascimento Bodolay
Faculdade Interdisciplinar em
Humanidades/UFVJM

Prof. Dr. Leonardo Lana de Carvalho
Departamento de
Computação/FACET/UFVJM

Diamantina

*A Deus, pelas bênçãos e pela vida, aos meus pais,
Geraldo e Sônia, aos meus irmãos, Izabela e Brener,
e à Maria Thereza.*

AGRADECIMENTOS

Agradeço, inicialmente, a Deus, que tem iluminado meus caminhos ao longo de toda minha vida, principalmente no desenrolar dessa valiosa etapa.

Aos meus pais e grandes incentivadores, Geraldo e Sônia, que sempre confiaram no meu sucesso sendo as principais referências na minha vida. Aos meus irmãos, Izabela e Brenner, pela paciência e por sempre acreditarem neste trabalho. À Maria Thereza, pelo carinho, apoio e confiança.

Aos meus orientadores, Profa. Dra. Luciana Assis e Prof. Dr. Alessandro Vivas que direcionaram e lapidaram este trabalho com muita paciência e empenho. Aos membros das bancas avaliadoras da qualificação e da defesa, Profa. Dra. Adriana Bodolay, Profa. Dra. Josiane Teixeira e Prof. Dr. Leonardo Lana, que contribuíram com sugestões de melhorias valiosas.

À UFVJM pelas oportunidades oferecidas ao longo dos quase 12 anos de estudo e trabalho.

RESUMO

Na modalidade de ensino a distância, os Ambientes Virtuais de Aprendizagem (AVAs) são elementos fundamentais no processo de ensino e aprendizagem, através da disponibilização de conteúdos e áreas de discussão e comunicação entre os atores do processo. Entretanto, tais ambientes, na sua maioria, caracterizam-se pelo fato de serem estáticos, abordando métodos pedagógicos genéricos através dos quais estudantes com características e Estilos de Aprendizagem (EAs) diferentes buscam o conhecimento. Dessa maneira, é importante que sejam levados em consideração os EAs de cada estudante como forma de tornar a aprendizagem mais eficaz. Questionários psicométricos na maioria das vezes são utilizados para que as características de aprendizagem do estudante sejam identificadas, porém nem sempre tais questionários apresentam resultados precisos quanto ao EAs de determinado estudante. Assim, faz-se necessária a utilização de outras técnicas de detecção, haja vista que uma identificação precisa é capaz de melhorar o processo de aprendizagem por meio de escolhas de estratégias pedagógicas melhores. Diante disso, surge a necessidade de utilização de sistemas inteligentes que se adaptem às características de aprendizagem do estudante, utilizando como pressupostos as experiências vivenciadas por ele e as análises estatísticas dessas experiências. Isso pode ser feito através de avaliações dos EAs apresentados pelo estudante, em que a partir dos resultados um novo modelo de aprendizagem do estudante é definido para que o conteúdo seja disponibilizado de acordo com esse modelo. Nesse intuito a presente abordagem objetivou identificar e corrigir os EAs do estudante por meio da utilização do conceito de Média Móvel Exponencialmente Ponderada no processo de decisão sobre a aplicação do reforço de maneira a ajustar o Modelo do Estudante (ME), de modo que os resultados obtidos, após a realização do teste estatístico não-paramétrico de Mann-Whitney, mostraram-se significativamente melhores do que os resultados apresentados por Dorça (2012), cujo trabalho foi referência para o desenvolvimento desta proposta.

Palavras-chave: Aprendizagem por Reforço, Estilos de Aprendizagem, Sistemas Inteligentes, Média Móvel Exponencialmente Ponderada.

ABSTRACT

In Distance Learning, Learning Management Systems (LMS) are extremely important elements in teaching and learning process, because they can offer content and spaces of discussion and communication between people who are part of that process. However they are static and do not consider students' Learning Styles (LS) to show the content, they just use the same pedagogical methods for all learners. It is important to consider students' Learning Styles because this can make the learning process more effective. Most of the time people use Psychometric Instruments to detect students' preferences, but sometimes the outcomes of those methods are not precise. Because of this other techniques of detection of LS can be used to identify precisely the student's LS and consequently to choose better pedagogical strategies than when are used manual techniques of detection of LS. For this reason intelligent systems which adapt to students' learning characteristics get importance since they use experiences and statistical analysis over these experiences to be adaptive. It can be done based on learner's Learning Styles that are adjusted by a part of the system, then these new LS are used by another part of the system to select a pedagogical strategy which fit to student's characteristics. Thus, this work presents an approach which aimed to identify and to correct the Learning Styles of the learner using for this the Exponentially Weighted Moving Average (EWMA) concept. This concept was used to decide if reinforcement signs have to be used to make the student's modeling. This approach was tested and the outcomes were submitted to non parametric test Mann-Whitney which pointed they were significantly better than the results of Dorça (2012), whose work was the base of the work presented here.

Keywords: Reinforcement Learning, Learning Styles, Intelligent Systems, Exponentially Weighted Moving Average.

LISTA DE ILUSTRAÇÕES

Figura 1 – Modelo de Estilos de Aprendizagem proposto por Kolb	34
Figura 2 – Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM) . .	36
Figura 3 – Escala de força dos EAs de uma mesma dimensão	37
Figura 4 – Modelo que representa a Taxonomia de Bloom Original (BLOOM et al., 1956)	39
Figura 5 – Modelo que representa a Taxonomia de Bloom Revisada	41
Figura 6 – Arquitetura de um STI	44
Figura 7 – Representação do funcionamento da AR	56
Figura 8 – Exemplo de Cadeia de Markov	58
Figura 9 – Cadeias de Markov na Composição da CEA selecionada	63
Figura 10 – Resultados de aplicações de MMEP com os respectivos valores para o fator de suavização $\theta = 0,4$; $\theta = 0,6$ e $\theta = 0,8$	70
Figura 11 – Gráfico que mostra o efeito de suavização obtido através da aplicação de MMEP	71
Figura 12 – Pirâmide hierárquica que apresenta os níveis da Taxonomia de Bloom .	76
Figura 13 – Distribuição dos dados em torno da média - Perfil 1 - Abordagem de Dorça	94
Figura 14 – Distribuição dos dados em torno da média - Perfil 1 - Abordagem de Ribeiro	94
Figura 15 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 1	96
Figura 16 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 1	96
Figura 17 – Distribuição dos dados em torno da média - Perfil 4 - Abordagem de Dorça	98
Figura 18 – Distribuição dos dados em torno da média - Perfil 4 - Abordagem de Ribeiro	98
Figura 19 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 4	100
Figura 20 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 4	100
Figura 21 – Distribuição dos dados em torno da média - Perfil 8 - Abordagem de Dorça	102
Figura 22 – Distribuição dos dados em torno da média - Perfil 8 - Abordagem de Ribeiro	103
Figura 23 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 8	104
Figura 24 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 8	104

Figura 25 – Distribuição dos dados em torno da média - Perfil 2 - Abordagem de Dorça	121
Figura 26 – Distribuição dos dados em torno da média - Perfil 2 - Abordagem de Ribeiro	122
Figura 27 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 2	122
Figura 28 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 2	123
Figura 29 – Distribuição dos dados em torno da média - Perfil 3 - Abordagem de Dorça	123
Figura 30 – Distribuição dos dados em torno da média - Perfil 3 - Abordagem de Ribeiro	124
Figura 31 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 3	124
Figura 32 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 3	125
Figura 33 – Distribuição dos dados em torno da média - Perfil 5 - Abordagem de Dorça	125
Figura 34 – Distribuição dos dados em torno da média - Perfil 5 - Abordagem de Ribeiro	126
Figura 35 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 5	126
Figura 36 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 5	127
Figura 37 – Distribuição dos dados em torno da média - Perfil 6 - Abordagem de Dorça	127
Figura 38 – Distribuição dos dados em torno da média - Perfil 6 - Abordagem de Ribeiro	128
Figura 39 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 6	128
Figura 40 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 6	129
Figura 41 – Distribuição dos dados em torno da média - Perfil 7 - Abordagem de Dorça	129
Figura 42 – Distribuição dos dados em torno da média - Perfil 7 - Abordagem de Ribeiro	130
Figura 43 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 7	130
Figura 44 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 7	131
Figura 45 – Distribuição dos dados em torno da média - Perfil 9 - Abordagem de Dorça	131
Figura 46 – Distribuição dos dados em torno da média - Perfil 9 - Abordagem de Ribeiro	132

Figura 47 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 9	132
Figura 48 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 9	133
Figura 49 – Distribuição dos dados em torno da média - Perfil 10 - Abordagem de Dorça	133
Figura 50 – Distribuição dos dados em torno da média - Perfil 10 - Abordagem de Ribeiro	134
Figura 51 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 10	134
Figura 52 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 10	135
Figura 53 – Distribuição dos dados em torno da média - Perfil 11 - Abordagem de Dorça	135
Figura 54 – Distribuição dos dados em torno da média - Perfil 11 - Abordagem de Ribeiro	136
Figura 55 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 11	136
Figura 56 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 11	137
Figura 57 – Distribuição dos dados em torno da média - Perfil 12 - Abordagem de Dorça	137
Figura 58 – Distribuição dos dados em torno da média - Perfil 12 - Abordagem de Ribeiro	138
Figura 59 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 12	138
Figura 60 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 12	139
Figura 61 – Distribuição dos dados em torno da média - Perfil 13 - Abordagem de Dorça	139
Figura 62 – Distribuição dos dados em torno da média - Perfil 13 - Abordagem de Ribeiro	140
Figura 63 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 13	140
Figura 64 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 13	141
Figura 65 – Distribuição dos dados em torno da média - Perfil 14 - Abordagem de Dorça	141
Figura 66 – Distribuição dos dados em torno da média - Perfil 14 - Abordagem de Ribeiro	142
Figura 67 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 14	142
Figura 68 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 14	142

Figura 69 – Distribuição dos dados em torno da média - Perfil 15 - Abordagem de Dorça	143
Figura 70 – Distribuição dos dados em torno da média - Perfil 15 - Abordagem de Ribeiro	143
Figura 71 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 15	144
Figura 72 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 15	144
Figura 73 – Distribuição dos dados em torno da média - Perfil 16 - Abordagem de Dorça	144
Figura 74 – Distribuição dos dados em torno da média - Perfil 16 - Abordagem de Ribeiro	145
Figura 75 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 16	145
Figura 76 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 16	145

LISTA DE TABELAS

Tabela 1 – Estilos de Aprendizagem armazenados no Modelo do Estudante	60
Tabela 2 – Tabela de probabilidades	64
Tabela 3 – EAs Probabilísticos da dimensão Entrada	75
Tabela 4 – Modelo do Estudante	76
Tabela 5 – Cálculo das probabilidades das CEAs	78
Tabela 6 – Representação do Módulo Pedagógico proposto neste trabalho	79
Tabela 7 – Definição das probabilidades no Modelo do Estudante	90
Tabela 8 – Média de sessões de aprendizagem por valor de θ	90
Tabela 9 – Médias de sessões de aprendizagem e seus desvios-padrão	92
Tabela 10 – Médias das notas e seus desvios-padrão	92
Tabela 11 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	94
Tabela 12 – Notas médias do estudante e seus respectivos desvios-padrão	95
Tabela 13 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	97
Tabela 14 – Notas médias do estudante e seus respectivos desvios-padrão	99
Tabela 15 – Notas e MMEP das últimas 10 sessões de aprendizagem - Perfil 4 . . .	101
Tabela 16 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	102
Tabela 17 – Notas médias do estudante e seus respectivos desvios-padrão	103
Tabela 18 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	121
Tabela 19 – Notas médias do estudante e seus respectivos desvios-padrão	121
Tabela 20 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	122
Tabela 21 – Notas médias do estudante e seus respectivos desvios-padrão	123
Tabela 22 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	124
Tabela 23 – Notas médias do estudante e seus respectivos desvios-padrão	125
Tabela 24 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	126
Tabela 25 – Notas médias do estudante e seus respectivos desvios-padrão	126
Tabela 26 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	128
Tabela 27 – Notas médias do estudante e seus respectivos desvios-padrão	128
Tabela 28 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	129
Tabela 29 – Notas médias do estudante e seus respectivos desvios-padrão	130
Tabela 30 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	131
Tabela 31 – Notas médias do estudante e seus respectivos desvios-padrão	131
Tabela 32 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	132
Tabela 33 – Notas médias do estudante e seus respectivos desvios-padrão	133
Tabela 34 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	134
Tabela 35 – Notas médias do estudante e seus respectivos desvios-padrão	135
Tabela 36 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	136

Tabela 37 – Notas médias do estudante e seus respectivos desvios-padrão	136
Tabela 38 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	137
Tabela 39 – Notas médias do estudante e seus respectivos desvios-padrão	138
Tabela 40 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	139
Tabela 41 – Notas médias do estudante e seus respectivos desvios-padrão	139
Tabela 42 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão	140
Tabela 43 – Notas médias do estudante e seus respectivos desvios-padrão	141

LISTA DE ALGORITMOS

1	Algoritmo <i>Q-learning</i> apresentado por Iglesias et al. (2009a)	57
2	Algoritmo <i>Q-learning</i> aplicado à modelagem automática e dinâmica de EAs proposto por Dorça (2012)	67
3	Algoritmo que utiliza MMEP e AR para detectar EAs	84

LISTA DE ABREVIATURAS

Ati	Ativo
Glo	Global
Int	Intuitivo
Prob	Probabilidade
Ref	Reflexivo
Sen	Sensitivo
Seq	Sequencial
Ver	Verbal
Vis	Visual

LISTA DE SIGLAS

AR	Aprendizagem por Reforço
AVA	Ambiente Virtual de Aprendizagem
AVAs	Ambientes Virtuais de Aprendizagem
CEA	Combinação de Estilos de Aprendizagem
CM	Cadeias de Markov
CME	Componente de Modelagem do Estudante
DEA	Diferenças entre as probabilidades dos Estilos de Aprendizagem de uma dimensão
EA	Estilo de Aprendizagem
EAs	Estilos de Aprendizagem
EaD	Educação a Distância
EC	Estado Cognitivo
FSLSM	Modelo de Estilos de Aprendizagem de Felder e Silverman
IA	Inteligência Artificial
ILS	Índice de Estilos de Aprendizagem
ME	Modelo do Estudante
MMEP	Média Móvel Exponencialmente Ponderada
MP	Módulo Pedagógico
OA	Objetivos de Aprendizagem
PESDE	Processo Estocástico de Simulação de Desempenho do Estudante
PFM	Performance, nota, desempenho
R	Reforço
STI	Sistema de Tutoria Inteligente
STIs	Sistemas de Tutoria Inteligentes

SUMÁRIO

1	INTRODUÇÃO	27
1.1	Objetivos	29
1.1.1	Objetivo Geral	29
1.1.2	Objetivos Específicos	29
1.2	Justificativa	29
1.3	Organização	30
2	REVISÃO DA LITERATURA	31
2.1	Estilos de Aprendizagem	31
2.1.1	Modelo de Estilos de Aprendizagem de Kolb	33
2.1.1.1	Inventário de Estilos de Aprendizagem	34
2.1.2	Modelo de Estilos de Aprendizagem de Felder e Silverman . .	35
2.1.2.1	Índice de Estilos de Aprendizagem de Felder-Soloman	37
2.2	Taxonomia de Bloom	38
2.3	Educação a Distância	41
2.4	Ambientes Virtuais de Aprendizagem	42
2.5	Sistemas de Tutoria Inteligentes	43
2.5.1	Modelo do Estudante	45
2.6	Hipermídia Adaptativa	46
2.6.1	Sistemas de Hipermídia Adaptativa	48
2.7	Deteção Automática de Estilos de Aprendizagem	49
3	FUNDAMENTOS TEÓRICOS	55
3.1	Aprendizagem por Reforço	55
3.2	Processos Estocásticos	58
3.3	Abordagem proposta por Dorça (2012)	59
3.3.1	Modelo do Estudante	59
3.3.2	Módulo Pedagógico	61
3.3.3	Componente de Modelagem do Estudante	64
3.3.4	Processo Estocástico de Simulação de Desempenho do Estudante	66
3.4	Média Móvel Exponencialmente Ponderada	68
4	METODOLOGIA	73
4.1	Metodologia de desenvolvimento	73
4.1.1	Modelo do Estudante	74
4.1.2	Módulo Pedagógico	76

4.1.3	Componente de Modelagem do Estudante	79
4.2	Metodologia de experimentação	84
4.2.1	Escolha do melhor valor para θ	85
4.2.2	Realização dos experimentos	85
4.2.3	Análise estatística	86
5	RESULTADOS E ANÁLISES	89
5.1	Escolha do melhor valor para θ	89
5.2	Resultados dos experimentos	91
5.2.1	Experimento com o Perfil 1	93
5.2.2	Experimento com o Perfil 4	97
5.2.3	Experimento com o Perfil 8	101
5.3	Análise estatística	105
6	CONCLUSÕES E TRABALHOS FUTUROS	107
	REFERÊNCIAS	111
	APÊNDICE A – EXPERIMENTOS NÃO APRESENTADOS NO CAPÍTULO 5	121

1 INTRODUÇÃO

A oferta de cursos na modalidade a distância tem crescido significativamente ao longo das últimas décadas. Com isso, o aumento da diversidade dos estudantes dessa modalidade de ensino é inevitável, fazendo com que diversos autores se preocupem em analisar e identificar os Estilos de Aprendizagem (EAs) de cada estudante na intenção de potencializar sua aquisição de conhecimento por meio do uso da tecnologia.

Desde o início da década de 1990, pesquisadores se preocupam em propiciar sistemas adaptativos, conforme apresenta Brusilovsky (2004). Esse mesmo autor afirma ainda que, em um mesmo sistema, pessoas com objetivos e conhecimentos diferentes podem utilizar métodos ou caminhos diferentes para alcançarem seus objetivos, deixando clara a existência de características individuais nos processos de aprendizagem.

Cada estudante tem uma forma particular de aprender, isto é, tem preferências sobre a forma como recebe e processa a informação. Sabendo disso, é possível potencializar o processo de aprendizagem do estudante, tornando-o mais rápido e eficaz. Porém, não se tem modelado essa característica nos atuais Ambientes Virtuais de Aprendizagem (AVA), o que se justifica pelo fato de tais ambientes não apresentarem o conteúdo de acordo com as preferências dos estudantes (DORÇA et al., 2011; DORÇA, 2012; SILVA, 2012).

Com o objetivo de buscar alternativas que proporcionem a melhora do processo de aprendizagem dos estudantes no que corresponde à rapidez e à efetividade de tal processo, Silva (2012) buscou correspondências entre os EAs dos estudantes e Estratégias de Aprendizagem. De forma diferente, Dorça et al. (2011) e Dorça (2012) buscaram a solução para esse problema na tecnologia.

Assume-se, com base nos estudos de Dorça et al. (2011), Dorça (2012) e Silva (2012), que EAs correspondem às formas como os indivíduos recebem e processam a informação. Por sua vez, Estratégias de Aprendizagem são sequências de procedimentos ou atividades que os indivíduos utilizam para obter conhecimento, conforme defende Silva (2012).

Segundo Dorça et al. (2011) e Dorça (2012), alguns autores buscam identificar os padrões de comportamento dos estudantes a partir de suas ações nas plataformas de aprendizagem. No entanto, isso pode caracterizar uma falha no processo de modelagem de um sistema. Um exemplo disso é a possibilidade de o estudante ter as suas preferências modificadas durante o processo de aprendizagem, o que em um sistema determinístico não é levado em consideração. Assim, o processo de aprendizagem caracteriza-se como um processo não-determinístico.

Atualmente, existem ferramentas que permitem inferir os EAs dos estudantes, o que geralmente é feito antes do processo de aprendizagem. Essas ferramentas são questionários submetidos aos estudantes, em que as preferências são inferidas a partir das

respostas apresentadas.

Sabendo que ao longo do processo de aprendizagem as preferências dos estudantes podem sofrer modificações e que os questionários são apresentados geralmente antes do início do processo, a proposta de detecção e correção automática e dinâmica de EAs mostra-se bastante promissora. Isso porque os ajustes sobre as preferências dos estudantes são feitos de forma recorrente (DORÇA, 2012).

Havendo diferenças entre as preferências dos estudantes, torna-se necessário tratar o estudante de forma individualizada no AVA. Com base nessa necessidade de tratamento individual, os estudos sobre adaptatividade em ambientes educacionais têm crescido consideravelmente.

Mesmo com a crescente utilização da adaptatividade nesses ambientes educacionais, muitos sistemas ainda utilizam questionários para identificar os EAs do estudante. Tal fato serve como estímulo na busca por tecnologias que possibilitem a detecção e a correção automática e dinâmica desses EAs.

Alguns trabalhos sobre adaptatividade já foram propostos, como é o caso dos trabalhos de Andrius et al. (2006), Iglesias et al. (2009a), Iglesias et al. (2009b), Ghadirli e Rastgarpour (2013) e Dascalu et al. (2015). Outro exemplo é o trabalho apresentado por Dorça (2012), cujos resultados foram bastante significativos e no qual este trabalho se baseia.

Em seu trabalho, Dorça (2012) propõe um modelo capaz identificar e corrigir automática e dinamicamente os EAs dos estudantes. Esse modelo é baseado em Aprendizagem por Reforço e, de acordo com os resultados apresentados, o processo foi concluído com um baixo tempo de convergência.

Tempo de convergência é a principal métrica para avaliação do desempenho de algoritmos. Por tempo de convergência entende-se o tempo ou a quantidade de iterações que o algoritmo necessita para atingir o seu objetivo. Portanto, quanto menor o tempo de convergência, mais rápido o algoritmo atinge o objetivo.

Considerando essas informações, esta proposta objetiva otimizar o processo de detecção e correção dos Estilos de Aprendizagem do estudante do método proposto por Dorça (2012), aplicando o conceito de Média Móvel Exponencialmente Ponderada no desenvolvimento de um modelo de detecção automática e dinâmica de EAs. Esse modelo é submetido ao processo de aprendizagem por meio de simulação computacional, em que os dados fornecidos pela simulação são analisados estatisticamente, o que caracteriza esta pesquisa como quantitativa e não aplicada. Além de não aplicada e quantitativa, esta pesquisa é de caráter experimental, uma vez que os resultados obtidos pela abordagem aqui apresentada são comparados com os dados obtidos pelo método desenvolvido por Dorça (2012) no intuito de aceitar ou refutar uma hipótese desenvolvida.

1.1 Objetivos

1.1.1 Objetivo Geral

O sistema apresentado por Dorça (2012) simula a interação entre o estudante e um Ambiente Virtual de Aprendizagem. O seu desempenho é considerado satisfatório se for superior a 60, em uma escala de 0 a 100. Assim, em uma determinada sessão de aprendizagem, se o desempenho for inferior a 60, o sistema aplica um reforço e ajusta o Modelo do Estudante (ME).

Porém, por ser um processo estocástico, o desempenho do estudante não depende apenas dos EAs do estudante. Outros fatores podem fazer com que esse desempenho seja abaixo do mínimo exigido, como o estado emocional do estudante, por exemplo.

Assim sendo, para minimizar a interferência de fatores aleatórios no ajuste do ME, o objetivo deste estudo é aplicar o conceito de Média Móvel Exponencialmente Ponderada (MMEP), abordado por Box, Hunter e Hunter (2005), no processo de decisão da aplicação do reforço sobre as probabilidades presentes no ME, otimizando assim o processo de detecção e correção dos EAs do estudante em relação ao que é proposto por Dorça (2012).

1.1.2 Objetivos Específicos

Esta proposta apresenta, ainda, os seguintes objetivos específicos:

- Fazer uma reflexão sobre os conceitos e trabalhos já propostos acerca de EAs, Hipermídia Adaptativa e Detecção Automática de Estilos de Aprendizagem;
- Estudar o conceito de MMEP, suas características e suas principais aplicações, com o objetivo de melhor adequar tal conceito à realidade desta proposta;
- Codificar a proposta aqui apresentada;
- Promover ajustes mais precisos no ME;
- Reduzir a quantidade de ajustes e, conseqüentemente, fazer com que o algoritmo atinja o objetivo mais rapidamente;
- Realizar, por meio de simulação computacional, testes sobre esta abordagem com o intuito de verificar e validar o método proposto.

1.2 Justificativa

A qualidade do processo de aprendizagem dos estudantes é algo que há certo tempo intriga estudiosos da área de educação. Isso pode ser notado a partir da quantidade de trabalhos desenvolvidos nessa área, os quais, na maioria das vezes, têm o intuito de

apontar indicadores dessa falta de qualidade. A evasão é o principal desses indicadores, sendo alvo de diversos trabalhos.

Um desses trabalhos que aborda a evasão na educação a distância é o trabalho desenvolvido por Laguardia (2009). Nele, o autor lista e descreve vários fatores que influenciam a evasão na educação a distância, dentre os quais merecem destaque a frustração pelo fraco desempenho dentro do curso, a falta de tempo para conciliar estudos e trabalho e a não adaptação à metodologia de ensino da instituição.

Dessa forma é possível perceber a importância de se alinharem estilos de ensino e EAs no processo de aprendizagem. Dorça et al. (2011) e Dorça (2012) afirmam que, a partir desse alinhamento, a aprendizagem é facilitada.

Hwang et al. (2013) também apresentam a importância do alinhamento entre EAs e a forma escolhida para o processo de aprendizagem. Além disso, os mesmos autores também expõem a vulnerabilidade do processo de identificação de estilos de aprendizagem através de questionários de forma manual.

O primeiro passo para se alcançar essa facilidade na aprendizagem é identificar as preferências dos estudantes com precisão, o que pode ser feito através da tecnologia que, além de precisão, garante a rapidez do processo. A partir de uma identificação precisa e rápida é possível construir um modelo do estudante mais fiel à realidade, contribuindo com a qualidade na construção do conhecimento do aluno (DORÇA et al., 2011).

O método utilizado como ponto de partida para a presente proposta faz uso do desempenho do estudante de forma simples para decidir pela aplicação ou não de reforços aos EAs. Contudo, ajustes desnecessários podem ocorrer, o que implica em sessões de aprendizagem a mais, atrasando a convergência do algoritmo.

Para que não sejam realizados ajustes desnecessários nos EAs, o processo de decisão sobre a aplicação desses reforços faz uso de MMEP. A utilização dessa técnica permite que desempenhos obtidos anteriormente tenham influência no processo de decisão. Assim, o sistema tende a atingir seus objetivos com maior rapidez.

1.3 Organização

Este trabalho está organizado da seguinte forma. O Capítulo 2 faz uma breve revisão da literatura acerca dos assuntos abordados nesta proposta. No Capítulo 3, são apresentados os fundamentos teóricos que embasam o presente trabalho. Dessa maneira, os dois capítulos anteriores têm como função fornecer uma contextualização da abordagem aqui proposta. Assim sendo, o capítulo seguinte, 4, apresenta a abordagem fruto deste estudo. Depois de conhecida a abordagem, os testes que verificam e validam as contribuições são apresentados no Capítulo 5. Por fim, no Capítulo 6, são apresentadas as considerações finais acerca do estudo realizado bem como as propostas para o desenvolvimento de trabalhos futuros.

2 REVISÃO DA LITERATURA

Este capítulo tem como objetivo apresentar alguns conceitos fundamentais para o entendimento do trabalho e está organizado da seguinte maneira: inicialmente são apresentados conceitos sobre EAs na seção 2.1, seguidos de dois dos principais modelos de EAs e os instrumentos que permitem a identificação dos estilos do estudante conforme os respectivos modelos. Na seção 2.2 é descrito o conceito de Taxonomia de Bloom. A seção 2.3 apresenta brevemente o conceito de Educação a Distância (EaD). Em seguida, a seção 2.4 detalha aspectos dos Ambientes Virtuais de Aprendizagem (AVAs). A seção seguinte, 2.5, conceitua e apresenta alguns trabalhos de relevância sobre Sistemas de Tutoria Inteligentes (STIs). O conceito de Hiperídia Adaptativa é apresentado na seção 2.6. Seguindo a linha da evolução desses ambientes de aprendizagem, a seção 2.7 trata da utilização de tecnologia como forma de identificar os EAs dos estudantes dentro dos AVAs.

2.1 Estilos de Aprendizagem

Em seu trabalho, Laguardia (2009) realiza um levantamento de fatores que podem exercer influência sobre a taxa de evasão nos cursos de educação a distância de uma maneira geral, não se restringindo a um nível específico. Nesse levantamento são listados os momentos em que pode acontecer o abandono, o qual varia desde antes mesmo da matrícula até poucos meses antes da conclusão do curso.

Além da identificação dos momentos em que a evasão pode ocorrer, o autor enumera trabalhos de diversos outros autores que tratam da evasão, destacando uma grande quantidade de fatores que podem influenciar esse fenômeno. Dentre essa grande quantidade de fatores, merecem relevância os seguintes:

- rotina e situações intensas vividas pelo estudante fora da instituição de ensino;
- problemas em conciliar trabalho e estudos;
- frustração com o desempenho dentro do curso;
- não adaptação à metodologia de ensino proposta pela instituição.

Diante desse cenário de preocupação, Laguardia (2009) apresenta propostas para a redução dessas taxas, de modo que a mais interessante dentre as listadas é a realização de um acompanhamento dos estudantes pelas instituições de ensino desde a sua aprovação nos processos seletivos até momentos após a conclusão do curso. Esse acompanhamento pode ser feito através de questionários de satisfação, bem como através da verificação do grau de aprendizagem do estudante.

Um dos itens apresentados por Laguardia (2009) também é considerado por Felder e Silverman (1988), Felder e Henriques (1995) e Felder e Spurlin (2005), que apontam que o fracasso no processo de aprendizagem pode ser consequência das diferenças entre as formas como os alunos melhor aprendem e as formas como o conteúdo é ensinado pelos professores.

Segundo Cassidy (2004), há uma aceitação geral de que as formas com que as pessoas preferem aprender influenciam na performance e nos resultados obtidos ao final do processo de aprendizagem. Assim, com o intuito de minimizar esse fracasso, Silva (2012) buscou correspondências entre Estilos de Aprendizagem e Estratégias de Aprendizagem.

Segundo Felder e Silverman (1988), Estilos de Aprendizagem representam as preferências com que o estudante recebe e processa a informação. Seguindo o mesmo raciocínio, Silva (2012) considera Estilos de Aprendizagem como sendo a forma que o indivíduo recebe e processa a informação de maneira a potencializar sua aprendizagem.

Por sua vez, Estratégias de Aprendizagem, de acordo com Silva (2012), são sequências de procedimentos ou atividades que os indivíduos utilizam para obter conhecimento, e que comumente são divididas em estratégias cognitivas e metacognitivas. As Estratégias Cognitivas ajudam o estudante a preparar a informação para depois absorvê-la e as Estratégias Metacognitivas levam o estudante a refletir sobre as Estratégias Cognitivas utilizadas por ele.

Talvez por deficiências relativas à amostra e aos métodos aplicados em seus estudos, Silva (2012) não conseguiu identificar uma correlação significativa entre esses dois conceitos. Diante dessa não correlação significativa apresentada como resultado de estudos anteriores, passou a ser utilizado no presente trabalho apenas o conceito de Estilos de Aprendizagem.

Em seu trabalho, Coffield et al. (2004) fazem o levantamento dos diversos modelos de Estilos de Aprendizagem já propostos, bem como instrumentos que permitem a inferência dos EAs segundo tais modelos. Eles identificaram mais de 70 modelos de EAs distribuídos entre 5 famílias. Esses modelos foram criados com diferentes propósitos. Alguns pesquisadores, ao produzi-los têm apenas a intenção de contribuir com a teoria de EAs, de maneira que nem chegam a produzir instrumentos que permitam a identificação dos estilos presentes no modelo. Outros, porém, os desenvolvem com a intenção de fornecer ferramentas que permitam tal identificação para o uso cotidiano.

Dentre os modelos existentes, os principais, conforme aponta Silva (2012), são os modelos propostos por Kolb e por Felder e Silverman. Esse fato se justifica pela quantidade de trabalhos científicos dos quais são objetos de estudo e pelo fato de terem seus instrumentos de aplicação validados.

A seguir, na seção 2.1.1, são apresentadas as características do modelo proposto por Kolb. Além disso, na seção 2.1.1.1, é apresentado o Inventário de Estilos de Aprendizagem, elaborado com a finalidade de identificar os EAs conforme a proposta de

Kolb. Depois de apresentado o modelo de Kolb, o modelo defendido por Felder e Silverman é detalhado na seção 2.1.2. O questionário utilizado na identificação de EAs seguindo a abordagem desses autores é apresentado na seção 2.1.2.1.

Esses modelos são apresentados porque são considerados dois dos principais modelos de EAs abordados na literatura, devido ao fato de terem instrumentos de mensuração validados, conforme aponta Silva (2012). Esses aspectos são somados ao fato de se adequarem melhor à presente proposta e à fácil implementação. Diante disso, o sistema proposto neste trabalho é baseado no Modelo de Estilos de Aprendizagem de Felder-Silverman (FSLSM).

2.1.1 Modelo de Estilos de Aprendizagem de Kolb

De acordo com Coffield et al. (2004), o modelo proposto por Kolb é um dos mais influentes Modelos de Estilos de Aprendizagem já propostos. A prova disso é que esse modelo é abordado em uma quantidade considerável de pesquisas.

A intenção de desenvolver um modelo de EAs surgiu da insatisfação ao observar métodos tradicionais de ensino e aprendizagem presenciais. A partir dessa observação, Kolb começou a atentar-se às preferências dos estudantes durante o processo de aprendizagem, chegando à conclusão de que essas preferências podem variar ao longo do processo (COFFIELD et al., 2004).

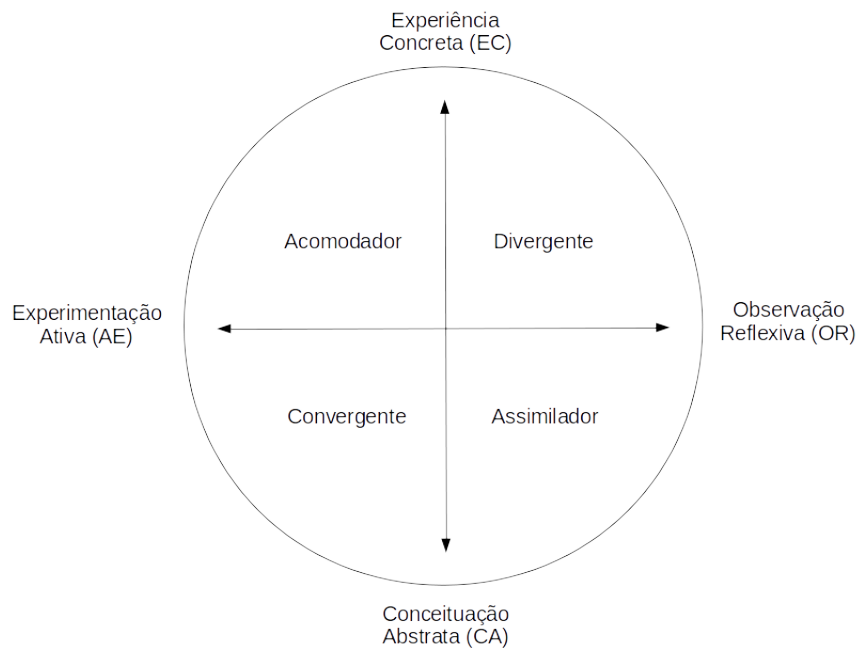
O modelo de Kolb representa o processo de aprendizagem como um ciclo composto de quatro estágios. Desses, 2 estão relacionados com a aquisição de experiência, e os demais com a transformação da experiência. A Experiência Concreta (EC), que favorece a aprendizagem através de experiências, e a Conceituação Abstrata (CA), que é quando o estudante prefere aprender por meio de abstrações, referem-se à captação da experiência. Por outro lado, a Experimentação Ativa (AE), que remete ao processo de aprendizagem por tentativa e erro, e a Observação Reflexiva (OR), que é quando o estudante analisa e levanta possíveis soluções antes de realizar qualquer tentativa, referem-se à transformação da experiência (FRY; KOLB, 1979; CASSIDY, 2004; KOLB; KOLB, 2005).

Além dos quatro estágios, fazem parte do modelo duas dimensões, sendo que a primeira aborda a forma como o estudante percebe a informação e a segunda trata da forma como o estudante processa a informação. Quanto à percepção, o estudante pode perceber de duas formas: EC ou CA, o processamento, por sua vez, acontece por meio de AE ou OR (CASSIDY, 2004; COFFIELD et al., 2004).

A Figura 1 (ver página 34), adaptada de Coffield et al. (2004), apresenta o modelo proposto por Kolb. Nela, cada quadrante compreende duas formas de aprendizagem, sendo uma de cada eixo. Diante disso, Cassidy (2004) e Coffield et al. (2004) definem que indivíduos com o perfil acomodador preferem perceber a informação de forma concreta e a processa de maneira ativa. Por outro lado, aqueles que têm o perfil divergente preferem perceber de forma concreta e processar por meio da observação reflexiva. Os estudantes

que são classificados como assimilador, tendem a preferir processar a informação de forma mais abstrata e percebê-la por meio da observação reflexiva. Por fim, os estudantes cujo perfil é convergente tendem a preferir perceber a informação de forma mais abstrata e processá-la por meio da experimentação ativa.

Figura 1 – Modelo de Estilos de Aprendizagem proposto por Kolb



Fonte – Coffield et al. (2004). Adaptado.

Os EAs do modelo de Kolb podem ser identificados a partir da aplicação do Inventário de Estilos de Aprendizagem. Geralmente essa ferramenta é utilizada por profissionais da área da educação para identificar os EAs dos estudantes, de forma a adequar as estratégias pedagógicas às preferências gerais da turma. Essa ferramenta é detalhada na seção 2.1.1.1.

2.1.1.1 Inventário de Estilos de Aprendizagem

Conforme explicam Coffield et al. (2004), o Inventário de Estilos de Aprendizagem (LSI, do inglês *Learning Styles Inventory*) foi lançado em 1976 e desde então passou por modificações até atingir sua versão atual em 1999.

Kolb (1981) apresenta o LSI como um questionário composto por 9 questões, em que cada questão apresentava 4 respostas: sentindo, assistindo, pensando e fazendo. O preenchimento do questionário se dava por meio de uma ordenação dessas respostas, em que a ordem era definida de acordo com as preferências da pessoa diante de cada situação (questão). Cada resposta estava associada a um modo de aprendizagem do modelo de Kolb: sentindo está associada à experiência concreta, assistindo está associada

à observação reflexiva, pensando está associada à conceituação abstrata, e fazendo está associada à experimentação ativa.

A partir de 1985, o LSI passou a ter 12 questões, conforme mencionam Cassidy (2004) e Fernandes, Benitti e Cunha (2013). O modo de aprendizagem é definido de acordo com a quantidade de respostas associadas a cada EA. Sabendo que ao todo foram respondidas 12 perguntas e que cada resposta poderia ter uma pontuação de 1 a 4, a pontuação mínima para um modo de aprendizagem é 12 e a pontuação máxima é 48. Assim, o EA que obteve a maior pontuação é o estilo que possui a pessoa que respondeu o questionário.

2.1.2 Modelo de Estilos de Aprendizagem de Felder e Silverman

Richard M. Felder e Linda K. Silverman desenvolveram em 1988 um modelo contendo 5 dimensões, em que cada uma dessas dimensões possuía 2 EAs diferentes, dando origem a 32 Combinações de Estilos de Aprendizagem (CEAs) possíveis (FELDER; SILVERMAN, 1988; SILVA, 2012).

Ao longo de alguns anos, o modelo proposto por Felder e Silverman em 1988 sofreu modificações, de maneira que Felder e Henriques (1995) já apresentam o modelo atualizado. Nesse trabalho, uma das dimensões já foi suprimida, passando o número de dimensões de 5 para 4. Isso interferiu diretamente na quantidade de CEAs possíveis, que antes era 32 e, a partir de então, passou a ser 16.

Silva (2012) define e apresenta o Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM), afirmando que, na dimensão referente à Percepção, o indivíduo pode optar entre a percepção sensorial ou intuitiva; na dimensão referente à Retenção, ele pode optar por visual ou verbal; na referente ao Processamento, as opções são ativo ou reflexivo; e, por fim, na dimensão referente à Compreensão, ou Organização, o indivíduo pode preferir sequencial ou global.

Outro trabalho que detalha o FSLSM é o trabalho defendido por Gonçalves (2015). Nele o autor apresenta as dimensões da seguinte forma:

- a dimensão do Processamento é composta pelos EAs Ativo e Reflexivo, e modela a forma como o estudante prefere trabalhar, se em grupo ou individualmente;
- a Percepção é a dimensão composta pelos EAs Sensitivo e Intuitivo, e corresponde à forma como o estudante prefere abstrair a informação, se através de fatos concretos percebidos por meio dos sentidos ou através de abstrações;
- na dimensão Entrada estão presentes os EAs Visual e Verbal, que definem se o estudante prefere aprender através da linguagem escrita (textos, gráficos, dentre outros) ou através da linguagem falada (áudios);

- a última dimensão, conhecida como dimensão da Organização, possui os EAs Sequencial e Global, que defendem se o estudante prefere aprender de forma evolutiva por meio de etapas ou de maneira aleatória, de modo que uma sequência dos itens a serem estudados não é definida.

A Figura 2 apresenta o FSLSM em seu formato atual, com 4 dimensões, em que cada dimensão possui 2 EAs.

Figura 2 – Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM)



Fazendo uma associação entre os EAs e as características dos estudantes, aqueles que preferem trabalhar com fatos concretos são identificados como sensoriais, ao passo que os intuitivos preferem a abstração. Considerando um AVA, os estudantes cujas preferências vão de encontro ao primeiro EA aprendem melhor através de exemplos apresentados dentro do conteúdo, como em fóruns de discussão. Por outro lado, os estudantes que preferem trabalhar com abstrações, tem a aprendizagem favorecida por meio da utilização de fórmulas e modelos.

Analizando a dimensão Entrada, os indivíduos classificados como visuais tendem a aprender melhor lembrando daquilo que já viram, sejam gráficos, diagramas, dentre outros. Por outro lado, dentro dessa mesma dimensão, estudantes que tendem a preferir uma forma de aprendizagem baseada palavras, sejam elas escritas ou faladas, são classificados como verbais. Materiais desse tipo podem ser fornecidos por professores, tutores e, até mesmo, pelos demais estudantes dentro das plataformas de aprendizagem.

Na dimensão identificada como Processamento, o estudante classificado como ativo tende a aprender melhor a partir de discussões em grupo, como por exemplo *chats* e fóruns de discussão. Em contrapartida, estudantes classificados como reflexivos aprendem melhor quando estudam sozinhos, o que favorece sua concentração durante os estudos.

Os indivíduos classificados como sequenciais têm como preferência no processo de aprendizagem a apresentação do conteúdo em etapas, seguindo uma sequência lógica. Alguns ambientes fornecem o conteúdo seguindo essa lógica, exigindo que, para aprender determinado conceito, os conceitos anteriores devem ser estudados. Outros, porém, permitem que o estudante navegue pelos conceitos de forma aleatória, sem que seja seguida

uma sequência lógica. Ambientes que adotam essa metodologia favorecem a aprendizagem dos estudantes classificados como globais, pois a liberdade dentro desse processo permite que ele atinja o aprendizado de maneira mais rápida (FELDER; SILVERMAN, 1988; FELDER; HENRIQUES, 1995; FELDER; SPURLIN, 2005; GRAF; VIOLA; LEO, 2007; DORÇA et al., 2011; DORÇA, 2012; SILVA, 2012).

Em 1991, conforme mencionam Felder e Spurlin (2005), Richard M. Felder e Barbara A. Soloman desenvolveram o Índice de Estilos de Aprendizagem de Felder-Soloman (ILS), ferramenta utilizada para identificar os estilos de aprendizagem das pessoas. Esse instrumento é detalhado na seção 2.1.2.1.

2.1.2.1 Índice de Estilos de Aprendizagem de Felder-Soloman

O Índice de Estilos de Aprendizagem de Felder-Soloman (ILS, do inglês *Index of Learning Styles*), segundo Silva (2012), é um questionário que permite identificar como o estudante prefere aprender. Em outras palavras, é uma ferramenta que permite identificar quais as preferências do estudante considerando cada dimensão do FSLSM.

A ferramenta é composta por 44 questões, sendo 11 questões referentes a cada dimensão do FSLSM. Ao responder o questionário, o estudante expõe suas preferências por um EA ou outro. Dessa forma, a cada resposta favorável a um EA, um ponto é atribuído a esse. Portanto, a pontuação máxima que um EA pode obter é 11, que é o caso em que o estudante responde todas as questões daquela dimensão evidenciando sua preferência por aquele EA.

A pontuação atribuída ao EA, quando concluída a aplicação do questionário, define a força do EA para aquele estudante, podendo essa ser forte, moderada ou leve. Isso é calculado a partir das diferenças entre as pontuações dos EA de uma mesma dimensão.

Quando a diferença entre os EAs de uma mesma dimensão for 1 ou 3, atribui-se o peso leve ao EA que possui maior pontuação. Quando ela for 5 ou 7, atribui-se o peso moderado e, finalmente, quando for 9 ou 11, é atribuído o peso forte.

A escala apresentada na Figura 3, adaptada de Silva (2012), mostra como pode variar a força dos EAs dentro de uma mesma dimensão. Nela, os números indicam a diferença entre as pontuações dos EAs depois de respondido o questionário e as tonalidades de cinza demarcam os níveis de força: a tonalidade mais escura indica que o EA é forte, a tonalidade intermediária indica moderado e a tonalidade mais clara, leve.

Figura 3 – Escala de força dos EAs de uma mesma dimensão

Estilo 1	11	9	7	5	3	1	1	3	5	7	9	11	Estilo 2
-----------------	-----------	----------	----------	----------	----------	----------	----------	----------	----------	----------	----------	-----------	-----------------

Fonte – Silva (2012). Adaptado.

Conforme relata Silva (2012), foram encontrados 9 trabalhos cujo objetivo era verificar a validade da ferramenta proposta por Felder e Soloman. Desses 9 trabalhos, 7 são internacionais e 2 são nacionais. De todos esses trabalhos, 6 validaram o ILS, afirmando que o método é estatisticamente confiável e eficaz na identificação de EAs.

Um exemplo de estudo que comprova a validade do ILS é o estudo desenvolvido por Felder e Spurlin (2005), no qual testes e análises estatísticas foram feitas comprovando a validade do instrumento. Segundo os autores da pesquisa que atesta a validade do ILS, duas aplicações foram encontradas para o questionário: ajudar os estudantes a identificar suas fraquezas no processo de aprendizagem e permitir que instrutores de cursos forneçam o conteúdo de forma mais apropriada. Além de seus experimentos e resultados, Felder e Spurlin (2005) apontam outros estudos que, apesar de sugerirem a continuidade de pesquisas sobre a validade do instrumento, atestam sua validade. Tais resultados, aliados ao fácil acesso à ferramenta, justificam o fato de o FSLSM e o ILS serem utilizados nessa abordagem e em vários outros estudos que abordam EAs.

2.2 Taxonomia de Bloom

A princípio, a Taxonomia de Bloom surgiu como uma ferramenta para facilitar a comunicação entre examinadores da área da Educação. Contudo, depois de discutirem o assunto mais a fundo, seus idealizadores chegaram à conclusão de que o instrumento poderia ser melhor elaborado com base nos objetivos do processo educacional (BLOOM et al., 1956). Assim, Ferraz e Belhot (2010) defendem que a ferramenta proposta tem como objetivo ajudar a planejar, organizar e controlar os objetivos de aprendizagem dos cursos.

O desenvolvimento da ferramenta, segundo Bloom et al. (1956), foi dividindo-a em 3 partes: Domínio Cognitivo, Domínio Afetivo e Domínio Psicomotor. O Domínio Cognitivo é a principal parte da ferramenta, utilizada no presente trabalho. É nela que os objetivos do processo educacional são apresentados, descritos como comportamento pretendido do estudante.

Ferraz e Belhot (2010) também discutem esses domínios e reforçam que, dos três, o mais conhecido e utilizado pelos educadores para definir planejamentos educacionais, objetivos, estratégias e sistemas de avaliação é o Domínio Cognitivo. Esse comportamento pretendido do estudante, do qual tratam Bloom et al. (1956), consiste nas formas como o estudante age, pensa e sente. Esse é o tipo de comportamento que a Taxonomia de Bloom classifica.


Bloom et al. (1956) ainda destacam que comportamento pretendido e comportamento real do estudante são dois aspectos distintos e que, inclusive, podem diferir em grau e espécie.

A estrutura da taxonomia no Domínio Cognitivo, segundo Bloom et al. (1956), mostra seis principais classes de objetivos, que estão organizadas de forma a seguir uma hi-

erarquia cumulativa. Isso significa que os objetivos presentes em uma classe são formados pelos objetivos presentes na classe anterior e objetivos específicos da classe atual.

Essas características também são lembradas por Krathwohl (2002) e Ferraz e Belhot (2010), que citam que, para o estudante atingir o nível mais complexo, todos os menos complexos devem ter sido dominados. As classes, ou categorias, que formam o Domínio Cognitivo da taxonomia proposta por Bloom et al. (1956) são: Conhecimento, Compreensão, Aplicação, Análise, Síntese e Avaliação. A Figura 4 apresenta essas categorias de forma hierárquica. Nela, a hierarquia está representada pela composição, de maneira que o elemento mais externo possui todas as características de todos os elementos internos a ele, mais as suas especificidades.

Figura 4 – Modelo que representa a Taxonomia de Bloom Original (BLOOM et al., 1956)



A primeira classe, Conhecimento, é descrita por Bloom et al. (1956) como a classe cujos comportamentos e situações remetem à lembrança, como o reconhecimento de materiais ou ideias. Por sua vez, a classe identificada como Compreensão é aquela que possui objetivos, comportamentos e respostas que representam o entendimento do conhecimento transmitido.

A classe Aplicação representa o poder de aplicação de um conceito já lembrado e compreendido por parte do estudante. Ao passo que a Análise consiste no fato de desmembrar um material em partes menores e analisar como essas partes se organizam e se relacionam para compor o material (BLOOM et al., 1956).

Por sua vez, a Síntese compreende o processo inverso ao descrito na classe anterior. Essa classe consiste na união das partes menores de maneira a constituir algo maior, o que deixa transparecer o comportamento criativo do estudante, conforme escl-

rece Bloom et al. (1956). Por fim, a Avaliação, como o próprio nome já diz, consiste no julgamento, quantitativo ou qualitativo, do que foi produzido ao longo do processo educacional.

Segundo Ferraz e Belhot (2010), com a criação da taxonomia, houve uma padronização dos termos utilizados na gestão dos objetivos de aprendizagem, o que proporcionou maior clareza e considerável avanço para a elaboração e gestão dos objetivos instrucionais.

Contudo, considerando o avanço tecnológico e a grande produção científica nessa área, Ferraz e Belhot (2010) destaca que foram necessárias reavaliações da taxonomia proposta, o que fez com que mudanças sobre ela fossem propostas.

Krathwohl (2002) faz uma revisão do modelo original, propondo um *framework*¹ que trata as categorias não mais como nomes, mas como verbos, ações. Além disso, o autor também propôs alterações na ordem de algumas dessas categorias e as subdividiu em duas dimensões: Dimensão do Conhecimento e Dimensão do Processo Cognitivo.

Essas alterações foram mais consideráveis no âmbito da nomenclatura e da organização das categorias dentro do modelo. Dessa forma, foi mantida uma das principais características do instrumento: a hierarquia cumulativa.


Ferraz e Belhot (2010) citam as alterações realizadas na taxonomia original e destacam que o Domínio Cognitivo da taxonomia manteve-se com 6 categorias: lembrar, entender, aplicar, analisar, avaliar e criar. Percebe-se que os nomes que anteriormente eram substantivos, com as mudanças propostas, passaram a ser verbos. A Figura 5 (ver página 41) apresenta a Taxonomia de Bloom revisada, conforme discutem Krathwohl (2002) e Ferraz e Belhot (2010).

Essas mudanças em relação à proposta original, feita por Bloom e sua equipe, não influenciam de forma significativa neste trabalho. Isso porque o conceito da taxonomia é aqui abordado de forma simples e objetiva, em que o que influencia é a quantidade de categorias existentes no Domínio Cognitivo. Como essa quantidade foi mantida após as alterações promovidas por Krathwohl (2002), o modelo computacional desenvolvido pode ser utilizado tanto em abordagens anteriores ao trabalho de Krathwohl (2002), quanto aos trabalhos posteriores a ele.

Em seguida, na seção 2.3, o conceito de Educação a Distância é apresentado. Nessa seção também é discutida a evolução desse conceito ao longo dos anos.

¹ Conforme defendem Johnson (1997) e Pree e Sikora (1997), *frameworks* são arquiteturas de softwares compostas por padrões e classes abstratas considerados elementos genéricos e classes concretas que correspondem aos elementos específicos do software que utiliza essa arquitetura. Seu objetivo é fornecer funcionalidades às aplicações que as utilizam. *Frameworks* proporcionam reusabilidade de código, o que confere melhor qualidade ao software.

Figura 5 – Modelo que representa a Taxonomia de Bloom Revisada



2.3 Educação a Distância

Ao contrário do que comumente se pensa, a Educação a Distância não é uma modalidade de ensino nova. Esse equívoco talvez ocorra devido ao fato de, atualmente, a modalidade estar profundamente associada e, talvez, dependente da tecnologia.

Fritsch (2001) destaca que a Educação a Distância (EaD) teve início aproximadamente na metade do século XIX com cursos de idiomas, nos quais o material era fornecido por meio de correspondências. Esse tipo de ensino, conforme destaca o autor, era comum em ambientes rurais, e teve seus meios de transmissão do conhecimento evoluídos, em que as correspondências deram lugar aos recursos eletrônicos.

Essa evolução foi melhor explicada por Simonson, Schlosser e Orellana (2011), que a defendem dividindo-a em três fases:

- a primeira fase é caracterizada pelo uso de correspondências como forma de transmissão do conhecimento;
- a segunda se caracteriza pela utilização de recurso de transmissão analógica, como rádio e televisão, por parte das universidades;
- a terceira tem como recurso de transmissão as tecnologias digitais.

Portanto, nota-se que o conceito de EaD não é algo recente, mas que sofreu modificações durante sua história devido à evolução dos meios de comunicação.

A definição de EaD, para Fritsch (2001), é de que ela consiste em uma forma de ensino em que as instruções, as interações, o monitoramento das práticas e o controle do aprendizado é feito por meio de recursos, não exigindo a presença simultânea de tutores e estudantes.

Em uma abordagem mais moderna, Milman (2015) define a Educação a Distância no século XXI como uma modalidade de ensino em que o estudante aprende por meio de tecnologias digitais, de forma síncrona ou não, em local diferente do local onde o instrutor se encontra. Exemplos dessas tecnologias digitais são os Ambientes Virtuais de Aprendizagem (AVAs), os quais são discutidos na seção 2.4.

2.4 Ambientes Virtuais de Aprendizagem

Na concepção de Cavus (2015), Ambientes Virtuais de Aprendizagem (AVAs) são plataformas² que permitem a gestão de tarefas envolvidas no processo de aprendizagem, dentre as quais merecem destaque a gestão do conhecimento, a gestão do processo de aprendizagem dos estudantes, a comunicação entre os atores envolvidos no processo e a entrega dos conteúdos. Desenvolvidos com o intuito de fornecer, monitorar e gerenciar conteúdos educacionais, os AVAs ainda são capazes de armazenar informações sobre o estudante, tais como seu progresso e seu desempenho dentro do curso (CAVUS; ALHIH, 2014).

É evidente que esse tipo de ferramenta torna a aprendizagem mais acessível, oferecendo aos estudantes benefícios como a flexibilidade de horários e possibilidade de acessar o conteúdo em diferentes locais. Diante disso, diversas plataformas já foram desenvolvidas, cada uma com suas particularidades, mas sempre contendo as características básicas de um AVA, como realizar a gestão do conteúdo e proporcionar aos estudantes, tutores e professores, acesso a ambientes de troca de informações.

Sabendo dessa diversidade de plataformas, Cavus e Zabadi (2014) realizaram um trabalho em que são avaliadas 6 plataformas de aprendizagem de código fonte aberto: ATutor, Claroline, Dokeos, Ilias, Moodle, e Sakai. As avaliações foram realizadas apenas sobre as ferramentas de comunicação disponibilizadas por cada AVA, de modo a identificar aquela plataforma que apresenta os melhores recursos. Ao final da avaliação foi verificado que o AVA que obteve melhores resultados foi o Moodle.

Se por um lado vários autores identificam o AVA como fator determinante e capaz de exercer influência sobre o processo de aprendizagem, por outro, autores identificam tal ferramenta como um elemento neutro dentro desse processo. É o caso de Peixoto (2015), que os aponta como elementos responsáveis por fornecer conteúdos preparados por professores.

² Plataformas, neste contexto, são sistemas computacionais que podem ser acessados através da Internet.

O fato de um conteúdo ser apresentado da mesma forma a diferentes estudantes pode ser uma prova de que o AVA é um elemento neutro no processo de aprendizagem. Porém, ao longo dos últimos anos, diversas pesquisas têm sido realizadas no intuito de permitir que essas plataformas apresentem o conteúdo de forma “inteligente”, levando em consideração as preferências e as características do estudante que a utiliza. São exemplos dessas pesquisas as realizadas por Phobun e Vicheanpanya (2010), Zaina et al. (2012) e Silva e Dorça (2014). Nesse sentido ganha força o conceito de Sistemas Tutores Inteligentes ou Sistemas de Tutoria Inteligentes (STIs).

2.5 Sistemas de Tutoria Inteligentes

Desde sua origem, a tecnologia já evoluiu muito, mas ainda é comum se deparar com perguntas do tipo: até onde a tecnologia pode chegar? Como será o mundo, no que se refere à tecnologia em 10, 20, 50 anos? São esses tipos de perguntas, aliadas a outros fatores como o interesse pelo processo de criação, que ditam o ritmo do desenvolvimento tecnológico.

Em seu trabalho, Millward et al. (1978) propuseram o desenvolvimento de um Sistema Inteligente de Instruções Assistido por Computador. Naquela época, a aplicação de Inteligência Artificial (IA) em sistemas de Instruções Assistidos por Computador (CAI) não era muito comum. Mas, apesar de raros, já existiam estudos a respeito de IA em sistemas CAI. Dois desses estudos são os realizados por Carbonell (1970), que utiliza o conceito de rede semântica para fornecer flexibilidade ao seu sistema, e por Brown, Burton e Bell (1975), que ressaltam que é perfeitamente possível incorporar inteligência em sistemas CAI.

Esses trabalhos serviram de base para o desenvolvimento da parte “inteligente” do software BANDAID proposto por Millward et al. (1978). Além disso, os autores perceberam que a inteligência também poderia ser aplicada nos sistemas CAI analisando os diálogos das interações entre tutor e estudante. Ao final dos experimentos do *software* desenvolvido, eles chegaram à conclusão de que essa nova forma de ensinar era agradável e eficaz. Isso porque os estudantes gostam de obter as respostas para as suas dúvidas de forma instantânea.

A partir de então, vários estudos envolvendo IA e CAI foram surgindo. Um exemplo disso é o trabalho defendido por Payette (1990), que abordou as terminologias: sistemas CAI e sistemas CAI Inteligentes. Ele desenvolveu em seu trabalho um *software*, utilizando conceitos de IA, CAI, processamento de linguagem natural, dentre outros, que analisa de forma interativa o estilos sintáticos dos seus usuários e fornece, como retorno, instruções que contribuirão com a aprendizagem do usuário. Assim, uma de suas propostas foi fornecer recursos ausentes nos sistemas CAI através do uso de IA, destacando nesses sistemas problemas de comunicação e flexibilidade.

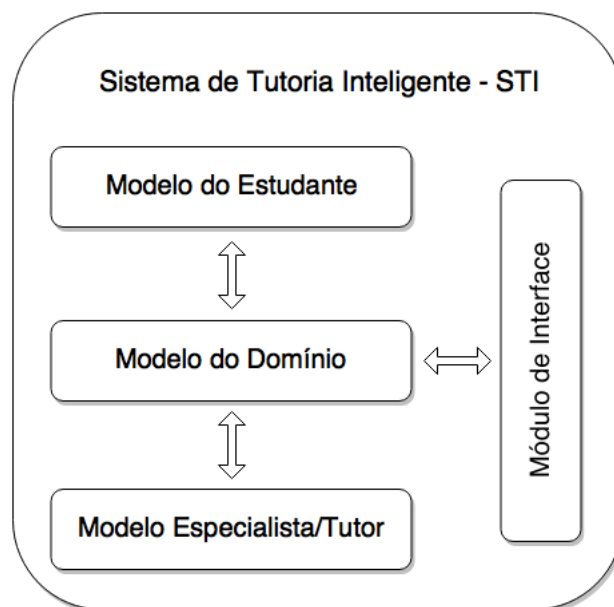
Contudo, ao longo do seu trabalho, o conceito de Sistemas de Tutoria Inteligentes (STIs) ganhou certo destaque. Apesar de não haver uma data específica em que uma terminologia deixou de ser utilizada e deu lugar a outra, é aproximadamente nessa época, 1990, que o conceito de STI passou a ser difundido com maior intensidade.

Essa evolução é mencionada no trabalho de Phobun e Vicheanpanya (2010), no qual o autor afirma que os sistemas CAI fazem uso de métodos de ensino tradicionais, em que a informação segue apenas um sentido, da máquina para o estudante, e é apresentada da mesma forma para todos os estudantes. Por outro lado, os STIs apresentam o conteúdo de forma mais dinâmica e adaptada. Isso porque esse tipo de sistema armazena no Modelo do Estudante (ME) características e preferências dos estudantes, as quais são levadas em consideração no momento em que o conteúdo é selecionado para ser apresentado.

Assim, STIs são definidos por Brusilovsky e Millán (2007) como sistemas capazes de identificar as preferências do estudante através da interação desse com o sistema, e utilizar essas preferências como base de conhecimento para fornecer o conteúdo ao estudante de forma adaptada e dinâmica. Esse é o grande diferencial quando comparado aos sistemas CAI, conforme defendem Phobun e Vicheanpanya (2010).

Essa capacidade de fornecer o conteúdo de forma adaptada ao estudante só é possível devido à sua arquitetura, apresentada na Figura 6.

Figura 6 – Arquitetura de um STI



Fonte – (PHOBUN; VICHEANPANYA, 2010). Adaptado.

Os 4 elementos que compõem a Figura 6 são definidos por Silveira et al. (2011) da seguinte forma:

- o Modelo do Estudante é o componente do STI responsável por armazenar in-

formações sobre o estudante, tais como seu conhecimento e seu comportamento;

- o Modelo do Domínio faz a gestão dos materiais apresentados ao estudante, tais como áudios, vídeos, textos, gráficos, dentre outros;
- o Modelo Especialista ou Modelo Tutor é responsável pela seleção das estratégias pedagógicas ou materiais, ele é que decide se o estudante deve ler um texto ou escutar um áudio, por exemplo;
- o Módulo de Interface é o elemento que apresenta o conteúdo ao usuário.

É importante destacar que a forma como cada elemento de um STI realiza suas funções, depende da forma como o sistema foi modelado. Assim, um STI pode fazer a seleção das estratégias pedagógicas, ou armazenar as características do aluno, de forma diferente da que é feita por outro sistema.

Neste trabalho, ajustes precisos são feitos no Modelo do Estudante, o que permite detectar de forma eficiente os EAs do estudante. Nesse sentido, a seção seguinte apresenta um detalhamento desse elemento.

2.5.1 Modelo do Estudante

Kara e Sevim (2013) deixam claro que, em sistemas adaptativos de aprendizagem, o estudante é quem define como será o seu processo de aprendizagem e seu ritmo. Depois de identificadas as características do estudante, elas são armazenadas no Modelo do Estudante (ME). Contudo, o processo de modelagem do estudante é uma etapa extremamente complexa do desenvolvimento de sistemas adaptativos de aprendizagem. Isso porque as inferências devem ser feitas com precisão, pois, caso contrário, ao invés de facilitar o processo de aprendizagem, a adaptatividade funcionará como um entrave para esse processo.

Assim, a adaptatividade é dependente do ME, que, de acordo com Kobsa (1994), contém as inferências que o sistema faz sobre as características do aluno. Essas inferências são feitas pelo Componente de Modelagem do Estudante (CME), módulo capaz de fazer inferências com base no comportamento do usuário dentro do ambiente.

Dorça et al. (2011) e Dorça (2012) definem o ME como uma estrutura que armazena inferências acerca das características do estudante, como seu Estado Cognitivo (EC) que, de forma resumida, consiste no nível de conhecimento que o estudante possui sobre determinado conceito; seus EAs, que são as formas como o estudante prefere aprender; e seus Objetivos de Aprendizagem (OA), que são os conceitos que devem ser aprendidos durante a sessão de aprendizagem.

Em seu trabalho, Dorça (2012) mantém a estrutura do ME, que é ajustado a cada sessão de aprendizagem em que o estudante não atinge o desempenho mínimo exigido. Isso é feito por meio de Aprendizagem por Reforço, de maneira que o reforço é

calculado em função do desempenho do estudante, conforme equação 3.4, detalhada na seção 3.3.3.

2.6 Hipermídia Adaptativa

Antes de conceituar Hipermídia Adaptativa (HA), é fundamental a apresentação de outros 3 conceitos: Multimídia, Hipertexto e Hipermídia.

Multimídia, na concepção de Incontri (1996), “é uma linguagem eletrônica, produzida em computador, que une diferentes linguagens de arte e comunicação — texto, imagem, som, animação, vídeo [...]”. De forma mais objetiva, Najjar (1996) define multimídia como a apresentação de informação através de recursos do tipo texto, gráfico, animação, imagens, vídeo e som.

Na concepção de Lévy (1993), hipertexto é um conjunto de elementos dispostos de maneira não linear, em que cada elemento pode conter uma rede de subelementos dispostos, também, de maneira não linear. Assim, a navegação entre esses elementos pode ser feita de diversas maneiras e não de forma predefinida. Cabe ainda lembrar que esses elementos podem ser páginas, gráficos, documentos, imagens, palavras, dentre outros.

Por sua vez, Hipermídia, na opinião de Burgos (2010), é

“[...] um sistema ou interface computacional virtual ou digital, formada por linguagens verbais e não verbais, hibridizadas em hipertextos virtuais, cores, sons, animações, gráficos vetoriais, imagens, vídeos, *hyperlinks* e ícones, que se interconectam interativamente e promovem navegação não-linear.”

Percebe-se, pela definição acima, que Hipermídia é a união dos dois conceitos anteriores: Multimídia e Hipertexto. A partir desse ponto, surge a possibilidade de tornar a hipermídia adaptativa, pois, como já mencionado, cada pessoa tem uma forma específica pela qual prefere aprender. Considerando esse fato, a forma como uma pessoa utiliza um sistema será diferente da forma como outras pessoas o utilizam. Isso porque as preferências de cada pessoa poderão determinar a maneira como elas navegam pelo sistema em busca dos seus objetivos.

Cientes de que a tarefa mais importante dos STIs era dar suporte ao estudante no processo de solução de problemas, grupos de pesquisa passaram a considerar a combinação entre Hipermídia e STIs, para que o conteúdo pudesse ser apresentado ao estudante da forma que ele prefere aprender (BRUSILOVSKY, 2000). Como as preferências variam de pessoa para pessoa, um mesmo sistema deveria ser capaz de fornecer o conteúdo de forma individualizada, considerando as preferências do usuário que o utiliza.

Para Neto (2007), adaptatividade consiste na capacidade que os sistemas dotados dessa característica possuem de, com base no histórico do seu comportamento e nas entradas recebidas, adaptar seu comportamento de forma autônoma. Uma solução para esse problema é o uso da Hipermídia Adaptativa (HA) no desenvolvimento de AVAs.

Com a utilização dessa tecnologia, um sistema até então estático pode se tornar dinâmico, fornecendo o conteúdo de acordo com as preferências e os objetivos do usuário (BRUSILOVSKY, 2004).

Ainda segundo Brusilovsky (2004), a HA no âmbito educacional passou por três fases, sendo que na primeira dessas fases havia apenas uma classificação das páginas que os estudantes acessavam como relevantes ou não relevantes. Na segunda fase, que compreende o período entre 1996 e 2002, as pesquisas na área de HA se tornaram mais difundidas. A principal contribuição dessa fase foi o considerável aumento na utilização de sistemas web para fins educacionais. Na terceira, percebe-se um maior esforço dos estudiosos em promover adaptatividade, através de técnicas de Inteligência Artificial (IA), de forma efetiva em AVAs, considerando as características dos estudantes e seus objetivos.

Brusilovsky (2001) afirma que a adaptatividade pode ser fornecida em nível de conteúdo e em nível de navegação. A Apresentação Adaptativa (AA) fornece o conteúdo de forma adaptada, diferente da Navegação Adaptativa (NA), que consiste em fornecer os *links* de navegação de forma adaptada (BRUSILOVSKY, 1996; BRUSILOVSKY, 2000; SILVEIRA et al., 2011).

De uma forma mais detalhada, Phobun e Vicheanpanya (2010) afirmam que AA consiste na apresentação do conteúdo de acordo com as necessidades identificadas a partir das informações presentes no Modelo do Estudante (ME) e que NA ajuda o estudante, através da apresentação de *links*, a encontrar o melhor caminho para aprender o conteúdo, de modo que os *links* são fornecidos com base nas informações presentes no ME.

Sob outra perspectiva, mas com o mesmo objetivo, Graf, Kinshuk e Ives (2010) propuseram um *framework* que provê adaptatividade a AVAs a partir do conceito de EAs, tomando como base o FSLSM. Nesse sentido, a adaptatividade ocorre através das técnicas de anotação adaptativa, que consiste em assinalar quais Objetos de Aprendizagem (OAs) o estudante deve acessar, e ordenação adaptativa, que define o posicionamento dos OAs dentro das sessões de aprendizagem.

Hwang et al. (2013) também evidenciam a relevância do alinhamento entre EAs e HA, uma vez que os estudantes precisam de auxílio para escolherem formas de atingir um aprendizado cada vez melhor, deixando clara a necessidade de sistemas inteligentes e dinâmicos que forneçam o conteúdo de forma adequada a eles.

Nota-se que a detecção dos Estilos de Aprendizagem dos estudantes e o fornecimento de conteúdo dinâmico a eles é algo que preocupa pesquisadores há um bom tempo. Na tentativa de tornar os sistemas voltados para a educação cada vez mais dinâmicos, várias abordagens foram propostas. A maioria dessas propostas surgiram na terceira fase da HA, apresentada por Brusilovsky (2004). Essa fase se caracteriza pela larga aplicação de conceitos de IA como forma de inserir adaptatividade em AVAs.

2.6.1 Sistemas de Hipermissão Adaptativa

De acordo com Brusilovsky (1996), Sistemas de Hipermissão Adaptativa (SHAs) constroem um modelo de objetivos, preferências e conhecimento dos estudantes, e o utiliza ao longo do processo de aprendizagem para fornecer o conteúdo de maneira a atender às necessidades do aluno.

Por sua vez, Kavcic (2000) afirma que eles são sistemas resultantes da fusão entre Sistemas de Hipermissão Educacional (SHEs) e Sistemas de Tutoria Inteligentes (STIs). Os primeiros são sistemas por meio dos quais o conteúdo é apresentado utilizando hipermissões. Por outro lado, STIs são sistemas em que o conteúdo é fornecido ao estudante de forma individualizada, considerando suas particularidades.

Os SHAs são apresentados por Phobun e Vicheanpanya (2010) de uma forma diferente. Em seu trabalho, os autores os chamam de Sistemas Tutores Inteligentes Adaptativos (STIAs) e os definem como a união entre STIs e HA, de modo que a HA se concentra no Modelo Especialista do STI. Nesse modelo há a seleção, com base nas informações armazenadas no ME e no repositório de conteúdos, do conteúdo a ser apresentado para o estudante.

Na concepção de Silveira et al. (2011), SHAs são sistemas que utilizam técnicas e métodos adaptativos para fornecer adaptatividade com base em um modelo contendo objetivos, preferências e conhecimento dos estudantes construído pelo próprio sistema.

Percebe-se que, mesmo com diferenças de nomenclaturas e de definições, todos os autores apresentam a mesma ideia acerca dos Sistemas de Hipermissão Adaptativa. Assim, eles podem ser definidos como sistemas dotados de certa inteligência cuja finalidade é fornecer ao estudante o conteúdo de forma adaptada às suas necessidades e características.

Um exemplo de sistema que se encaixa nessa linha de raciocínio é o sistema proposto por Ghadirli e Rastgarpour (2013), que fornece o conteúdo de forma adaptativa ao usuário, levando em consideração o seu comportamento, as suas características e o seu conhecimento, além de se basear em EAs.

Inicialmente, esse sistema classifica o aprendiz de acordo com seu nível de conhecimento por meio de um teste inicial no qual perguntas devem ser respondidas. Com base nas respostas, uma pontuação é calculada, o que define o nível do aluno. Em uma segunda etapa, o conteúdo é apresentado de acordo com a classificação inicial, a qual define se determinado conceito deve ser removido do conteúdo, realocado dentro do conteúdo ou até mesmo apresentado novamente. Por fim, um novo teste é aplicado de forma a atualizar a classificação, a qual é armazenada no Modelo do Estudante.

Em 2001, Brusilovsky (2001) já vislumbrava que, em 10 anos, haveria integrações entre os SHAs e outros sistemas, que eles já teriam bases de informações abertas e que haveria SHAs desenvolvidos especificamente para dispositivos móveis. Além disso, a utilização de novos recursos da Inteligência Artificial (IA) contribuiriam para o progresso da HA. Outro ponto destacado pelo autor como promissor é o desenvolvimento de novas

arquiteturas de SHAs. Entretanto, esse processo é mais complexo do que parece ser, pois a adaptatividade está diretamente relacionada a uma eficiente detecção automática de Estilos de Aprendizagem.

2.7 Detecção Automática de Estilos de Aprendizagem

A detecção automática de EAs consiste em um dos elementos que compõem a modelagem do estudante. Ela pode ser feita de forma implícita ou de forma explícita. A forma explícita consiste na aplicação do questionário ao estudante e, com base nas suas respostas, o seu EA é inferido. Por sua vez, o método implícito consiste em uma modelagem dinâmica que pode ser realizada de 3 formas: com base na performance do estudante, a partir de informações fornecidas por eles próprios ou através de análises do seu comportamento durante sua interação com o AVA (POPESCU, 2009).

Neste trabalho, é abordado o método implícito, uma vez que a identificação dos EAs do aluno ocorre de maneira dinâmica e transparente ao usuário, no caso, ao estudante. Isso é feito com base na performance do estudante, de modo que ao final de cada sessão de aprendizagem, ele é submetido a uma avaliação cujo resultado definirá se ajustes devem ser aplicados no Modelo do Estudante.

Ainda de acordo com autora, ambos os métodos apresentam vantagens e desvantagens. O método explícito, apesar de muito simples, é um método estático. Essa característica o torna impreciso, uma vez que as preferências do estudante podem mudar durante o processo de aprendizagem. Por outro lado, o método implícito tem a desvantagem de ser bastante complexo. Contudo, esse método caracteriza-se por ser invisível aos atores do processo de aprendizagem, devido ao fato de a detecção ser feita de forma natural pelo sistema, necessitando apenas que o estudante interaja com ele. Além disso, a detecção implícita é dinâmica, o que significa que os resultados alcançados por esse método são mais precisos, pois variam de acordo com as preferências do estudante.

Feldman, Monteserin e Amandi (2015) também destacam algumas fragilidades do processo de detecção explícito, em que algumas delas até coincidem com as apresentadas por Popescu (2009). Algumas das fragilidades apontadas por eles são:

- falta de motivação ou paciência por parte dos estudantes ao preencher tais questionários;
- desconhecimento dos estudantes sobre suas preferências de aprendizagem;
- variação dos EAs de um estudante ao longo do processo de aprendizagem, o que não é identificado através do questionário.

Esses aspectos apontam a necessidade de se desenvolverem ferramentas capazes de fazer a identificação dos EAs de forma transparente e dinâmica. Nesse sentido, a

presente abordagem adota um método implícito, no qual o desempenho do aluno é levado em consideração para que o sistema realize a modelagem do estudante. Essa modelagem é feita sempre que o próprio sistema julgar necessário, isso contribui para que o processo de detecção seja dinâmico, independentemente, portanto, do conteúdo apresentado ao estudante. Assim, caso suas preferências de aprendizagem modifiquem durante o processo, sejam essas mudanças devidas ao conteúdo ou não, o sistema será capaz de ajustar-se, com base na performance do aluno, para que o conteúdo seja apresentado de forma adequada a ele.

De acordo com Feldman, Monteserin e Amandi (2015), a detecção automática de EAs é um processo no qual é criado um modelo do usuário que armazena as preferências de aprendizagem do estudante enquanto ele utiliza o sistema. Todo esse processo é realizado de forma automática pelo sistema, no qual os desenvolvedores utilizam técnicas de IA, como Redes Neurais, Árvores de Decisão, Aprendizagem por Reforço, dentre outras. A seguir são apresentados alguns dos trabalhos já desenvolvidos no âmbito de detecção automática de EAs.

O trabalho de Kelly e Tangney (2005) consiste na proposta de utilização de Aprendizado de Máquina para determinar dinamicamente os EAs de um estudante. Nele são utilizados o algoritmo de classificação Naïve Bayes e o Índice de Estilos de Aprendizagem de Felder e Soloman (ILS), com o intuito de observar a forma como o estudante interage com o sistema. A partir dessa observação, o sistema realiza a inferência dos EAs do estudante.

Graf e Kinshuk (2006) utilizam o comportamento dos estudantes para tentar identificar de forma automática seus EAs. Isso é feito através da interação dos usuários com os AVAs, de modo que é contabilizada a frequência com que eles utilizam determinados recursos do ambiente.

Por sua vez, García et al. (2007) desenvolveram uma ferramenta utilizando o conceito de Redes Bayesianas (RB) para detectar EAs de estudantes que faziam uso de Ambientes Virtuais de Aprendizagem (AVAs). A inferência dos EAs nessa ferramenta se dá a partir do comportamento do estudante nesses ambientes, o que leva o sistema a fazer a modelagem do usuário.

O sistema proposto por Özpolat e Akar (2009) faz a modelagem do estudante de acordo com seu comportamento, utilizando como base o FSLSM. Além disso, o sistema faz a classificação dos estudantes de acordo com seus interesses, em que, para isso, são utilizados algoritmos de classificação por Relevância Binária e a mescla entre Árvores de Decisão e Naïve Bayes (NBTree).

A proposta de trabalho de Dorça et al. (2012b) consiste no desenvolvimento de um modelo baseado em Combinações de Estilos de Aprendizagem (CEA) como forma de prover a correção das inconsistências do Modelo do Estudante (ME) de forma dinâmica, considerando o processo de aprendizagem como um processo não determinístico. Nela, o ME foi definido como a combinação entre dois conceitos: Estilos de Aprendizagem (EAs)

e Níveis Cognitivos (NC). Para tratar os EAs, foi utilizado FSLSM e, para tratar NCs, foi utilizada a Taxonomia de Bloom. Por se tratar de um sistema que aborda o processo de aprendizagem como um processo não determinístico, ME armazena as preferências do estudantes como probabilidades. A modelagem do estudante é feita por meio de Aprendizagem por Reforço (AR), enquanto a seleção dos tipos de materiais a serem apresentados para o estudante é feita por meio do método da roleta, muito comum em algoritmos genéticos. Essa seleção é feita de maneira estocástica a partir das probabilidades dos EAs presentes no ME.

Assim como na proposta de Dorça et al. (2012b), este trabalho aborda os conceitos de EAs, Taxonomia de Bloom, AR e Cadeias de Markov. Porém, além deles, a presente proposta utiliza o conceito de Média Móvel Exponencialmente Ponderada aliado ao desempenho do estudante para que o sistema infira quando deve ser ajustado o ME.

Utilizando métodos computacionais que analisam o comportamento dos estudantes, Ahmad et al. (2013) apontam que existem duas formas de direcionar os estudos sobre detecção de EAs. A primeira delas imita o ILS e utiliza os dados obtidos para inferir os EAs. A outra forma, por sua vez, realiza a inferência com base nas preferências e no comportamento do estudante.

No mesmo ano Ahmad e Tasir (2013) buscaram identificar os EAs desses estudantes utilizando os logs de atividades online de um curso de Multimídia Interativa e o FSLSM. Como resultado, os autores identificaram, por meio da computação, que os padrões variam de acordo com a estrutura do curso, o assunto e o nível de experiência ou conhecimento do estudante.

Percebe-se uma grande utilização do modelo de EAs proposto por Felder e Silverman nos trabalhos já mencionados. De forma semelhante, esta abordagem baseia-se em tal modelo, uma vez que implementá-lo computacionalmente não é uma tarefa difícil.

Dorça et al. (2013a), por sua vez, realizaram a comparação entre dois métodos não determinísticos e não estacionários utilizados para detecção e correção de EAs: Cadeias de Markov (CM) e Algoritmos Genéticos (AG). Foi identificado que os AG detectam os EAs mais rapidamente, ao passo que as CM apresentam resultados mais precisos, levando em consideração a força dos seus EAs.

Outro trabalho é o de Dorça et al. (2013b). Nele são apresentadas 3 maneiras diferentes de ajustar o ME, utilizando o algoritmo *Q-learning*:

- incrementar as probabilidades dos EAs quando o desempenho do estudante for satisfatório: desempenho igual ou superior ao mínimo exigido, o que significa que o estudante não apresentou problemas no processo de aprendizagem;
- decrementar as probabilidades dos EAs quando o desempenho do estudante for insatisfatório: igual ou superior ao mínimo exigido, o que significa que foram identificados problemas no processo de aprendizagem;

- incrementar e decrementar, quando o estudante obtém bom e mau resultados respectivamente.

Ainda em 2013, Pham e Florea (2013) desenvolveram um trabalho no qual foi proposto um novo método de detecção automática e dinâmica de EAs baseado no comportamento do estudante que consistiu em identificar os Objetos de Aprendizagem (OA) associando-os aos EAs do FSLSM. Por exemplo, um acesso ao fórum de discussões está associado ao EA Ativo, em que o indivíduo prefere aprender por meio de discussões e argumentações. A título de teste, foram comparados os resultados obtidos a partir da proposta com os resultados obtidos através do ILS, de modo que os resultados da proposta mostraram-se promissores.

No ano seguinte, Feldman, Monteserin e Amandi (2014) desenvolveram um trabalho cujo objetivo é identificar os EAs de usuários de um jogo, em que, para isso, é utilizado um Classificador Naïve Bayes e a dimensão Percepção do FSLSM, cujos EAs são: Sensitivo e Intuitivo.

Em 2016, Gonçalves et al. (2016) apresentaram um trabalho, no qual melhorias sobre o método proposto por Dorça (2012) foram apresentadas. Nessa proposta, além de promover ajustes quando o desempenho do estudante é inferior a 60, os autores sugerem a aplicação de ajustes no ME, também, quando esse desempenho é considerado de excelência. Isso ocorre sempre que o estudante obtém uma nota superior a 90% ou 95%, dependendo da forma como o sistema é configurado. Além disso, a escolha da estratégia pedagógica, desenvolvida por Dorça (2012) com base apenas nas probabilidades dos EAs, passou a considerar, também, a média aritmética dos desempenhos do estudante para cada EA.

No mesmo ano, Rodrigues et al. (2016) apresentam uma proposta de detecção de EAs, na qual a escolha das estratégias pedagógicas ocorre por meio de Lógica *Fuzzy*. Nesse trabalho, os autores consideram a nota do estudante como muito ruim, ruim, média, boa ou muito boa. Essa classificação ocorre com base em equações que definem o grau de pertinência de cada nota aos conjuntos definidos. Depois de montado o histórico das médias para cada conjunto, as regras de Defuzzificação, definidas pelos autores, indicam o EA de cada dimensão do FSLSM que deve compor a estratégia pedagógica a ser utilizada na próxima sessão de aprendizagem.

Em 2017, Falci et al. (2017) apresentaram uma nova abordagem que permite a detecção de forma automática e dinâmica dos EAs do estudante, utilizando Aprendizagem por Reforço. Nessa abordagem, os autores utilizaram variações do cálculo do reforço apresentado por Dorça (2012) para fazer a modelagem do estudante. Além disso, a aplicação desses reforços era feita em função da nota obtida pelo estudante na última sessão de aprendizagem e em uma variação da média de todos os seus desempenhos. Dessa forma, os ajustes no ME podem ser feitos, tanto quando a nota do estudante for inferior a 60, quanto nos momentos em que ela for superior ou igual a 60.

É importante ressaltar a grande aplicação de Inteligência Artificial nas propostas elencadas. Contudo, percebe-se que em poucas delas é utilizada Aprendizagem por Reforço. Nesse sentido, o estudo aqui realizado busca aprimorar o processo de detecção dos EAs do estudante proposto por Dorça (2012), através de uma modelagem mais precisa, utilizando Aprendizagem por Reforço combinada com o conceito de Média Móvel Exponencialmente Ponderada. Tal combinação permite que a detecção seja mais rápida através de ajustes pontuais e precisos no ME, reduzindo a quantidade de sessões de aprendizagem para que os EAs sejam identificados.

3 FUNDAMENTOS TEÓRICOS

O presente capítulo apresenta alguns dos conceitos e recursos utilizados para o desenvolvimento do trabalho. Nele, a seção 3.1 expõe o conceito de Aprendizagem por Reforço (AR), um dos ramos da Inteligência Artificial, cuja utilização permite que sistemas tenham algum grau de “inteligência”. Em seguida, na seção 3.2, é discutido o conceito de processos estocásticos, apresentando uma das ferramentas que modelam esse tipo de processo, as cadeias de Markov. A seção 3.3 apresenta de forma detalhada a proposta de Dorça (2012). Nela são detalhados os módulos que compõem o modelo por ele proposto e a plataforma de simulação do processo de aprendizagem utilizada para validação de tal modelo. Por fim, na seção 3.4, é abordado o conceito de Média Móvel Exponencialmente Ponderada, conceito bastante utilizado nas áreas de engenharias e finanças, utilizado neste trabalho como recurso para uma detecção de EAs mais rápida e precisa.

3.1 Aprendizagem por Reforço


Inicialmente, é importante apresentar o conceito de agente, uma vez que a Aprendizagem por Reforço se dá através da interação entre um agente e ambiente em que ele se encontra. Para Russel e Norvig (2013), agente “é tudo o que pode ser considerado capaz de perceber seu ambiente por meio de sensores e de agir sobre esse ambiente por intermédio de atuadores.” Em outras palavras, agentes são algoritmos capazes de agir de forma autônoma, tomando decisões com base em informações captadas do ambiente em que eles se encontram.

Assim, Aprendizagem por Reforço (AR) é um campo da IA, cuja tarefa, segundo Russell e Norvig (2004, p. 739), “[...] consiste em usar recompensas observadas para aprender uma política ótima (ou quase-ótima) para o ambiente.” Essas recompensas são fornecidas com base em uma ação executada por um agente.

Em outras palavras, o funcionamento da AR consiste na aplicação de recompensas ou penalidades (reforços) a partir de cada decisão tomada pelo agente. Assim, se o agente tomar uma decisão acertada, o reforço atribuído é positivo, caracterizando uma recompensa. Caso o agente tome decisões erradas, o reforço é negativo, caracterizando uma penalidade (PERICO; BIANCHI, 2013). Esse funcionamento pode ser visto na Figura 7 (ver página 56).

Na Figura 7, o retângulo com o texto “Ambiente” representa o ambiente observado e modificado pelo agente, representado pelo outro retângulo. A observação e a modificação do ambiente são representadas pelas setas, de modo que o agente, representado pelo retângulo com o texto “Agente”, percebe o estado do ambiente, aplica determinada ação com base nesse estado, e recebe do próprio ambiente uma recompensa

Figura 7 – Representação do funcionamento da AR



Fonte – (RUSSEL; NORVIG, 2013). Adaptado.

pela ação executada.

Normalmente, a AR é utilizada quando não se tem conhecimento do ambiente no qual o agente está inserido, ou seja, quando não é possível aplicar a aprendizagem supervisionada, uma vez que o ambiente é desconhecido, conforme defende Dorça (2012).

Dessa maneira, a interação entre agente e ambiente ocorre através de uma sequência de etapas, de maneira que a dinâmica do processo é definida pelas ações que o agente executa, pelos estados do ambiente, pela função de transição entre esses estados do ambiente e pelo reforço obtido pelo agente através do ambiente (DORÇA, 2012).

Segundo Iglesias et al. (2009a), muitos algoritmos de AR são baseados em funções ganho, que definem o quão boa a política de ações é. Nesse sentido, percebe-se que o objetivo final do agente ao utilizar a função ganho é obter o melhor valor de reforço.

Essa função ganho é bem definida em Russell e Norvig (2004) através da equação 3.1:

$$Q(s, a) \leftarrow Q(s, a) + \alpha(R(s) + \gamma \max_{a'} Q[s', a'] - Q(s, a)) \quad (3.1)$$

Em que:

- $Q(s, a)$ é a qualidade da ação a no estado s ;
- α é a taxa de aprendizagem do agente e costuma ser um valor entre 0 e 1;
- $R(s)$ é o reforço aplicado para o estado s ;
- γ é o parâmetro que exerce o controle sobre as recompensas futuras;
- $Q(s', a')$ é a qualidade da ação futura a' no estado futuro s' .

Iglesias et al. (2009b), por sua vez, apresentam uma variação dessa função, a qual foi desenvolvida para atuar em ambientes não determinísticos. Nesse sentido, os autores utilizam a ferramenta proposta no processo de aprendizagem, já caracterizado neste estudo como um processo não determinístico. Como resultado, Iglesias et al. (2009b) comprovaram que as políticas pedagógicas podem ser atualizadas de acordo com resultados obtidos anteriormente por estudantes com características semelhantes.

Como forma de comparar a versão proposta em seu trabalho com a versão original do Algoritmo *Q-learning*, Iglesias et al. (2009a) coloca lado a lado os dois algoritmos. Fazendo isso, os autores deixam mais claro o funcionamento do algoritmo quando adaptado a Sistemas Adaptativos Inteligentes para Educação.

Uma versão adaptada do algoritmo *Q-learning* é abordada por Iglesias et al. (2009a), de modo que a versão original desse algoritmo é apresentada no Algoritmo 1:

Algoritmo 1 Algoritmo *Q-learning* apresentado por Iglesias et al. (2009a)

- 1: Para cada par $(s \in S, a \in A)$, inicializa a tabela $Q(s, a)$;
 - 2: Observa o estado atual, s ;
 - 3: **para** Até alcançar o objetivo **faça**
 - 4: Escolha e execute uma ação, a ;
 - 5: Receba a recompensa imediata, R ;
 - 6: Observe o novo estado s' ;
 - 7: Atualize a tabela de entrada $Q(s, a)$ conforme a equação 3.1;
 - 8: Atribua s' a s ;
 - 9: **fim para**
-

Sendo S o conjunto de estados s e A o conjunto de ações a , a princípio o algoritmo preenche a tabela de valores de qualidade $Q(s, a)$ através do cálculo da função ganho apresentada na equação 3.1. Estando a tabela preenchida com os valores de qualidade de cada ação para cada estado, o algoritmo inicia um laço de repetição até atingir uma condição de parada, que geralmente é quando o seu objetivo é alcançado.

A cada iteração uma ação $a \in A$ é executada, de modo que ao final dessa execução é feita uma avaliação para verificar a sua utilidade. Nesse ponto, o reforço é aplicado com base na utilidade calculada através da equação 3.1 e, conseqüentemente, a tabela com os valores de qualidade é atualizada.

De forma resumida e simples, a Aprendizagem por Reforço (AR) pode ser definida como um processo no qual um agente, com base no estado atual, executa determinada ação. Como resposta, o ambiente fornece uma recompensa pela ação executada e informa o seu novo estado. Nesse sentido, adaptada ao contexto do processo de aprendizagem a AR é utilizada nesta abordagem para a tornar o Modelo do Estudante cada vez mais parecido com o aluno, no que se refere aos seus EAs.

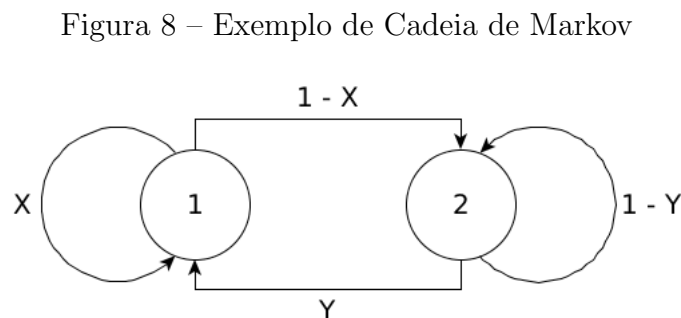
3.2 Processos Estocásticos

De acordo com Taylor e Karlin (1998), processos estocásticos são um conjunto de variáveis aleatórias X_t associadas a um parâmetro t que pertence a um conjunto T . Geralmente, o parâmetro t ao qual estão associadas as variáveis são momentos no tempo. Assim, a variável X_t indica o estado de um sistema no momento t .

Seguindo essa mesma linha, Pollard (1984) destaca que as variáveis de um processo estocástico são regidas por probabilidades, sendo um processo estocástico uma coleção de variáveis reais aleatórias definidas em um espaço comum de probabilidade. Em outra notação, as variáveis podem ser representadas da seguinte forma: $\{X_t : t \in T\}$.

Partindo dessas definições, e por considerar o processo de aprendizagem como não determinístico, Dorça (2012) utiliza em seu trabalho o conceito de processos estocásticos, pois, através desse recurso, o autor consegue modelar aspectos aleatórios ou imprevisíveis presentes no processo de aprendizagem. Para fazer essa modelagem, ele utilizou Cadeias de Markov.

As Cadeias de Markov, segundo Braghetto (2011), permitem que situações complexas e incertas do mundo real sejam modeladas através de estados e transições. Seu comportamento é definido por meio de probabilidades, sendo sua principal característica o fato de o estado futuro não depender de estados anteriores. Sua estrutura é representada na Figura 8.



Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

Assim, uma Cadeia de Markov pode ser representada graficamente por meio de Máquinas de Estados Finitos, cujos estados correspondem aos estados da cadeia e as transições da máquina são as probabilidades. Portanto, na Figura 8, os círculos contendo os números 1 e 2 representam os estados em uma Máquina de Estados Finitos, e as transições entre esses estados, representadas pelos arcos que os ligam, são as probabilidades.

Cadeias de Markov têm papel fundamental no trabalho Dorça (2012). Nele, o autor as utiliza no processo de seleção das estratégias pedagógicas, no intuito de selecionar aquela que melhor se encaixa no perfil do estudante em determinado momento. Esse processo é detalhado na seção 3.3.2.

3.3 Abordagem proposta por Dorça (2012)

Dorça (2012) desenvolveu um trabalho no qual foram abordados os conceitos de Estilos de Aprendizagem, Taxonomia de Bloom, Processos estocásticos — especificamente Cadeias de Markov e Aprendizagem por Reforço. Esse trabalho consistiu no desenvolvimento de um método automático e dinâmico de modelagem de estilos de aprendizagem de estudantes em sistemas adaptativos inteligentes para educação a distância.

O desenvolvimento do seu método foi dividido em módulos, de maneira que cada módulo trata informações acerca de determinado contexto. Esses módulos trabalham em conjunto, com o objetivo de identificar e corrigir os Estilos de Aprendizagem inferidos pelo sistema e armazenados no Modelo do Estudante.

Resumidamente, o Modelo do Estudante (ME), que é melhor apresentado na seção 3.3.1, é o módulo responsável por armazenar as preferências e demais informações sobre o estudante que interage com o sistema.

O Módulo Pedagógico (MP), conforme exposto na seção 3.3.2, tem como função armazenar e fornecer o conteúdo ao estudante de forma adaptada, em que para isso são levadas em consideração as informações presentes no ME.

O Componente de Modelagem do Estudante (CME), descrito na seção 3.3.3, é a parte do sistema em que são aplicadas as técnicas de Inteligência Artificial. A função do CME é atualizar as informações presentes no ME de modo a torná-lo mais fiel ao real perfil do estudante.

Por fim, Dorça (2012) desenvolveu um módulo que permite a simulação do processo de aprendizagem, do qual fazem parte o ME, o CME e o MP. A esse módulo de simulação o autor deu o nome de PESDE - Processo Estocástico de Simulação de Desempenho do Estudante e ele é apresentado na seção 3.3.4.

3.3.1 Modelo do Estudante

Dorça et al. (2011) definem o Modelo do Estudante (ME) como sendo o módulo do software responsável por representar as características do estudante. A partir dessas características são feitas inferências acerca do estado cognitivo e das preferências do aluno dentro do processo de aprendizagem. Essas mesmas informações que permitem a construção de inferências, em dado momento, são ajustadas no intuito de fazer com que o ME se aproxime cada vez mais do perfil do estudante.

Portanto, o Modelo do Estudante desenvolvido por Dorça (2012) é composto por Estilos de Aprendizagem (EAs), Objetivos de Aprendizagem (OA) e Estado Cognitivo (EC). Esses elementos são ajustados pelo Componente de Modelagem do Estudante ao final de cada sessão de aprendizagem em que o estudante não alcançar uma determinada nota. A sessão de aprendizagem pode ser definida como o processo em que um conceito é

apresentado ao estudante, que em seguida é submetido a uma avaliação acerca do conteúdo visto. Em outra notação, o ME é definido por Dorça (2012) como: $ME = \langle EA, OA, EC \rangle$.

No que se refere a Estilos de Aprendizagem, o ME armazena as probabilidades de o estudante pertencer a cada EA. Essas probabilidades representam os Estilos de Aprendizagem Probabilísticos, os quais podem ser definidos, inicialmente, pelo ILS. Conforme mencionado na seção 2.1.2.1, o ILS é um questionário composto por 44 perguntas, de modo que cada dimensão do FSLSM está associada a 11 perguntas.

No ME essa informação é armazenada como a probabilidade de preferência por um estilo ou outro, por exemplo, caso o estudante responda a 8 questões tendendo para o estilo sequencial e a 3 questões tendendo para o estilo global, a probabilidade de preferência pelo estilo sequencial da seguinte forma:

$$Prob_{seq} = \frac{8}{11} = 0,72$$

Por sua vez, o cálculo da probabilidade de preferência pelo estilo global é:

$$Prob_{glo} = \frac{3}{11} = 0,28$$

Faz-se importante saber que, como os EAs de cada dimensão são complementares, a soma das probabilidades das preferências dos dois estilos devem totalizar 1, conforme pode ser observado no exemplo acima:

$$Prob_{seq} + Prob_{glo} = 0,72 + 0,28 = 1$$

Para que o ME esteja completo, o procedimento acima é replicado para todas as demais dimensões que compõem o modelo. Assumindo que os valores se repetem, temos os EAs Probabilísticos armazenados no ME conforme mostra a Tabela 1:

Tabela 1 – Estilos de Aprendizagem armazenados no Modelo do Estudante

Estilos de Aprendizagem Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,72	0,28	0,72	0,28	0,72	0,28	0,72	0,28

Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

Além de armazenar os EAs, o ME também armazena os Objetivos de Aprendizagem (OA) e o Estado Cognitivo (EC) do estudante na intenção de verificar o nível de conhecimento do estudante diante dos conceitos ensinados. Como fundamento para a utilização desses conceitos foi utilizada a Taxonomia de Bloom.

Conforme Bloom et al. (1956) e Krathwohl (2002), a Taxonomia de Bloom é dividida em três domínios: Cognitivo, Afetivo e Psicomotor. O mais utilizado em

ambientes educacionais é o Cognitivo, servindo como ferramenta para classificar objetivos curriculares e itens de processos de avaliação. Essa ferramenta permite avaliar o quanto os requisitos atendem a cada categoria da Taxonomia.

O Domínio Cognitivo da Taxonomia de Bloom é um *framework* dividido em seis categorias: Lembrar, Entender, Aplicar, Analisar, Avaliar e Criar; no qual essas categorias seguem uma hierarquia cumulativa, o que significa dizer que, por exemplo, para que o estudante atinja o nível correspondente à Compreensão, ele deverá passar pelo nível Conhecimento, ou seja, para atingir o próximo nível de complexidade, o nível imediatamente anterior deve ter sido atingido (KRATHWOHL, 2002).

Ferraz e Belhot (2010) destacam a importância da Taxonomia de Bloom no processo de planejamento educacional, uma vez que o *framework* pode ser utilizado para avaliar o conteúdo aprendido e direcionar o processo de educacional de maneira a atingir os objetivos levantados na etapa de planejamento.

Tomando isso como base, o sistema trabalha com OA como sendo os conceitos a serem aprendidos pelo estudante e EC sendo o nível de conhecimento que o estudante possui sobre cada conceito apresentado. O EC é a representação da Taxonomia de Bloom dentro do software. Assim, quando o EC atinge 6º nível da taxonomia (Criar), um novo conceito é apresentado dados os Objetivos de Aprendizagem.

Conforme dito anteriormente, tal dispositivo é dividido em categorias, de modo que cada categoria é um nível do EC. Assim, o EC no sistema é uma escala de 0 a 5, compreendendo 6 níveis, sendo o primeiro correspondente à categoria Conhecimento da Taxonomia de Bloom, o segundo correspondente à categoria Compreensão, e assim por diante.

Dessa forma, tem-se ao todo, no que tange à Taxonomia de Bloom, no sistema, três conceitos: Objetivos de Aprendizagem (OA), Nível Cognitivo (NC) e Estado Cognitivo (EC), que podem ser resumidos da seguinte forma:

- OA: conceitos que serão apresentados ao estudante para que este os aprenda;
- NC: categorias propostas por Bloom et al. (1956): Conhecimento(0), Compreensão(1), Aplicação(2), Análise(3), Síntese(4), Avaliação(5); utilizadas para verificar se o estudante atingiu o objetivo (passou por todos os níveis da taxonomia);
- EC: nível atual do estudante, constantemente comparado ao NC no intuito de verificar se o estudante atingiu o objetivo que é atingir o nível máximo da taxonomia - Avaliação(5).

3.3.2 Módulo Pedagógico

O Módulo Pedagógico (MP) é responsável pela seleção das estratégias pedagógicas a que será submetido o estudante a cada sessão de aprendizagem. Isso é feito

levando em consideração as informações armazenadas no ME e utilizando o conceito de Cadeias de Markov (DORÇA, 2012).

A princípio, Felder e Silverman (1988) propuseram o Modelo de Estilos de Aprendizagem (FSLSM) com cinco dimensões, tendo cada dimensão dois estilos de aprendizagem. Entretanto, posteriormente, esse modelo passou por modificações até que em 2005 os estudos feitos por Felder e Spurlin (2005) verificaram a validade do FSLSM já com apenas quatro dimensões, o qual desde então vem sendo amplamente referenciado em pesquisas acerca de Estilos de Aprendizagem.

Como cada dimensão possui dois estilos de aprendizagem, tem-se ao todo oito estilos de aprendizagem: Ativo(*Ati*), Reflexivo(*Ref*), Sensitivo(*Sen*), Intuitivo(*Int*), Visual(*Vis*), Verbal(*Ver*), Sequencial(*Seq*) e Global(*Glo*).

A partir desses números, surge o conceito de Combinações de Estilos de Aprendizagem. Esse conceito é abordado por Franzoni et al. (2008) e Franzoni e Assar (2009), em que as CEAs foram utilizadas juntamente com estratégias de ensino e mídias eletrônicas como recursos para melhorar o processo de aprendizagem de estudantes em um instituto de tecnologia no México.

Ao todo, existem dezesseis Combinações de Estilos de Aprendizagem (CEA), resultado de (2^4), em que:

- 2 é a quantidade de estilos de aprendizagem em cada dimensão do FSLSM;
- 4 é a quantidade de dimensões que compõem o FSLSM.

Sendo assim, pode-se dizer, de forma simplificada, que todo estudante possui uma das dezesseis combinações, conforme representado abaixo:


$$CEAs = \{(Ati, Sen, Vis, Seq), (Ati, Sen, Vis, Glo), (Ati, Sen, Ver, Seq), (Ati, Sen, Ver, Glo), (Ati, Int, Vis, Seq), (Ati, Int, Vis, Glo), (Ati, Int, Ver, Seq), (Ati, Int, Ver, Glo), (Ref, Sen, Vis, Seq), (Ref, Sen, Vis, Glo), (Ref, Sen, Ver, Seq), (Ref, Sen, Ver, Glo), (Ref, Int, Vis, Seq), (Ref, Int, Vis, Glo), (Ref, Int, Ver, Seq), (Ref, Int, Ver, Glo)\}$$

Considerando que o estudante possui um estilo de aprendizagem por dimensão, a cada sessão de aprendizagem o conteúdo é apresentado ao estudante pelo MP de acordo com uma CEA. Cada CEA, por sua vez, é selecionada estocasticamente com base nas informações armazenadas no ME (DORÇA, 2012).

Essa seleção estocástica se dá através do uso de Cadeias de Markov, de maneira que cada estado da cadeia representa um estilo de aprendizagem de uma dimensão do FSLSM. A transição dos estados representam as probabilidades de ocorrência do estilo de aprendizagem na composição da CEA. Sendo assim, são necessárias, portanto, quatro Cadeias de Markov para que a CEA seja composta, segundo Dorça et al. (2011) e Dorça (2012). Tal processo é representado graficamente na Figura 9 (ver página 63).

Na Dimensão Processamento, o estado 1 da Figura 9 representa o estilo de aprendizagem Ativo, ao passo que o estado 2 da mesma dimensão representa o estilo

Figura 9 – Cadeias de Markov na Composição da CEA selecionada



Fonte – (DORÇA et al., 2011; DORÇA, 2012; GONÇALVES, 2015). Adaptado.

de aprendizagem Reflexivo. Na Dimensão Percepção, o estilo de aprendizagem Sensitivo é representado pelo estado 1 e o estilo Intuitivo é representado pelo estado 2. Para a Dimensão Entrada temos o estado 1 representando o estilo de aprendizagem Visual e o estado 2 representando o estilo de aprendizagem Verbal. Por fim, na máquina de estados referente à Dimensão Organização, o estado 1 corresponde ao estilo de aprendizagem Sequencial, portanto, o estado 2 corresponde ao estilo de aprendizagem Global.

Como uma CEA é composta por quatro estilos de aprendizagem, sendo cada um pertencente a uma diferente dimensão, a probabilidade de pertinência de um estudante a uma categoria pedagógica corresponde à multiplicação das probabilidades de cada estilo de aprendizagem que compõe a CEA, afirma Dorça (2012).

Por exemplo, a probabilidade de preferência de um estudante pela CEA composta pelos estilos de aprendizagem Ativo, Sensitivo, Visual e Sequencial é dada por:

$$Prob_{(Ati,Sen,Vis,Seq)} = Prob_{Ati} \times Prob_{Sen} \times Prob_{Vis} \times Prob_{Seq}$$

Substituindo os valores de acordo com as Cadeias de Markov dadas como exemplo na Figura 9, tem-se:

$$Prob_{(Ati,Sen,Vis,Seq)} = 0,18 \times 0,18 \times 0,18 \times 0,18 = 0,0010$$

De acordo com os valores apresentados nas Cadeias de Markov anteriormente, a Tabela 2 apresenta as 16 CEAs e suas probabilidades (ver página 64). Como as probabilidades de cada dimensão são complementares, a soma das probabilidades de cada CEA é igual a 1.

Tabela 2 – Tabela de probabilidades

CEA	Probabilidade
$Prob_{(Ati,Sen,Vis,Seq)}$	$0,18 \times 0,18 \times 0,18 \times 0,18 = 0,0010$
$Prob_{(Ati,Sen,Vis,Glo)}$	$0,18 \times 0,18 \times 0,18 \times 0,82 = 0,0048$
$Prob_{(Ati,Sen,Ver,Seq)}$	$0,18 \times 0,18 \times 0,82 \times 0,18 = 0,0048$
$Prob_{(Ati,Sen,Ver,Glo)}$	$0,18 \times 0,18 \times 0,82 \times 0,82 = 0,0218$
$Prob_{(Ati,Int,Vis,Seq)}$	$0,18 \times 0,82 \times 0,18 \times 0,18 = 0,0048$
$Prob_{(Ati,Int,Vis,Glo)}$	$0,18 \times 0,82 \times 0,18 \times 0,82 = 0,0218$
$Prob_{(Ati,Int,Ver,Seq)}$	$0,18 \times 0,82 \times 0,82 \times 0,18 = 0,0218$
$Prob_{(Ati,Int,Ver,Glo)}$	$0,18 \times 0,82 \times 0,82 \times 0,82 = 0,0992$
$Prob_{(Ref,Sen,Vis,Seq)}$	$0,82 \times 0,18 \times 0,18 \times 0,18 = 0,0048$
$Prob_{(Ref,Sen,Vis,Glo)}$	$0,82 \times 0,18 \times 0,18 \times 0,82 = 0,0218$
$Prob_{(Ref,Sen,Ver,Seq)}$	$0,82 \times 0,18 \times 0,82 \times 0,18 = 0,0218$
$Prob_{(Ref,Sen,Ver,Glo)}$	$0,82 \times 0,18 \times 0,82 \times 0,82 = 0,0992$
$Prob_{(Ref,Int,Vis,Seq)}$	$0,82 \times 0,82 \times 0,18 \times 0,18 = 0,0218$
$Prob_{(Ref,Int,Vis,Glo)}$	$0,82 \times 0,82 \times 0,18 \times 0,82 = 0,0992$
$Prob_{(Ref,Int,Ver,Seq)}$	$0,82 \times 0,82 \times 0,82 \times 0,18 = 0,0992$
$Prob_{(Ref,Int,Ver,Glo)}$	$0,82 \times 0,82 \times 0,82 \times 0,82 = 0,4521$

Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

3.3.3 Componente de Modelagem do Estudante

De acordo com o que apresenta Dorça (2012), o Componente de Modelagem do Estudante (CME) é o elemento responsável por prover inteligência ao sistema proposto. Todo o processo de detecção e correção dos EAs probabilísticos do estudante é feito pelo CME.

A realização dessas tarefas é feita a partir da utilização de Aprendizagem por Reforço (AR). Nesse ponto é importante conceituar e identificar os elementos necessários para o desenvolvimento da AR bem como identificar os aspectos inerentes ao processo de aprendizagem que devem ser levados em consideração durante a aplicação da AR.

Conforme destacado na seção 3.1, a AR possui alguns elementos:

- conjunto de estados: conjunto de elementos representados no ME como valores entre 0 e 1, que representam as probabilidades de ocorrência de um EA;
- conjunto de ações: conjunto de CEAs disponíveis para que o sistema escolha aquela que irá maximizar a qualidade do processo de aprendizagem do estudante.;
- percepção do ambiente: utilização de parâmetros que permitem identificar o nível de conhecimento do estudante ao final do processo de aprendizagem;

- reforço: valor utilizado como ajuste das probabilidades, resultado de uma função que leva em consideração o estado atual e a ação tomada;
- função valor-ação (ganho): função que realiza uma estimativa da qualidade da ação tomada em dado momento, considerando o estado atual.

O funcionamento da AR nessa abordagem consiste em ajustar o ME de acordo com a utilidade da ação escolhida para aquela sessão de aprendizagem.

Dorça (2012) destaca que os ajustes no ME são feitos a partir de desempenhos não satisfatórios do estudante. Para isso, o autor definiu como parâmetro um valor mínimo x , em que, caso o desempenho do estudante seja inferior a esse valor, os ajustes são feitos no ME, o que indica um problema de aprendizagem.

Conforme discutido na seção 2.1.2, cada dimensão do FSLSM é composta por dois EAs, sendo assim, Dorça (2012) definiu que caso haja um problema de aprendizagem, cada EA pertencente à CEA selecionada tem suas probabilidades de ocorrência decrementadas, ao passo que seus EAs complementares dentro de cada dimensão têm suas probabilidades de ocorrência incrementadas. Esse decremento e incremento das probabilidades dos EA_p presentes no ME, são feitos a partir do sinal de reforço, elemento chave da AR.

Conforme notação apresentada por Dorça (2012), a atualização do ME se dá por meio de duas regras, $R1$ e $R2$ para cada dimensão do FSLSM:

$$\begin{aligned}
 R1 : (CEA[d_i] = A) &\rightarrow \\
 ME[d_i]_A &:= ME[d_i]_A - \alpha \times R, \\
 ME[d_i]_B &:= ME[d_i]_B + \alpha \times R \\
 R2 : (CEA[d_i] = B) &\rightarrow \\
 ME[d_i]_A &:= ME[d_i]_A + \alpha \times R, \\
 ME[d_i]_B &:= ME[d_i]_B - \alpha \times R
 \end{aligned}$$

De maneira que:

- $CEA[d_i]$ representa o EA da dimensão i pertencente à CEA selecionada;
- $ME[d_i]_A$ representa o valor do EA A para a dimensão i armazenado no ME;
- $ME[d_i]_B$ representa o valor do EA B para a dimensão i armazenado no ME;
- α representa a taxa de aprendizagem do agente;
- R representa o sinal de reforço a ser aplicado sobre os valores armazenados no ME.

A função ganho utilizada no algoritmo *Q-learning* foi ajustada para que pudesse se adequar à realidade do problema. Como esse é um problema não determinístico,

as variáveis da Equação 3.1 que estão associadas a aspectos futuros foram suprimidas, ficando a função ganho da seguinte forma:

$$Q(s, a) := Q(s, a) + \alpha R(s, a) \quad (3.2)$$

Uma observação importante feita pelo próprio autor é que as diferenças entre os EA_p (DEA) podem aumentar ou diminuir a cada sessão de aprendizagem. Isso porque o ajuste é feito sobre todos os EA_p e é dependente da composição da CEA.

Ponto determinante no processo de ajuste do ME, o valor do reforço é calculado a partir da performance (PFM) do estudante e das DEA, em que PFM é um valor entre 0 e 100 e a DEA é obtida a partir da Equação 3.3.

$$DEA = |ME[d_i]_A - ME[d_i]_B| \quad (3.3)$$

Assim, o valor do reforço é calculado a partir da Equação 3.4, que fornecerá um valor de reforço mais alto quando a performance for mais baixa. Por outro lado, com a intenção de evitar mudanças abruptas nos EA_p , quanto maior a DEA, menor o reforço.

$$R = \frac{1}{PFM \times DEA} \quad (3.4)$$

Outro item que merece atenção é o valor de α , que, no modelo proposto por Dorça (2012), representa a taxa de aprendizagem do agente. O autor define α com base em 2 premissas:

- seu valor não pode ser muito alto porque, assim, mudanças abruptas serão realizadas no ME. Isso é considerado pelo autor como indesejável, uma vez que o processo envolve incertezas;
- seu valor não pode ser muito pequeno porque isso fará com que a aprendizagem seja mais lenta, culminando em uma identificação mais demorada dos EAs.

Dessa forma, Dorça (2012) define o valor 0,5 para a taxa de aprendizagem do agente. O funcionamento da Aprendizagem por Reforço é apresentado no Algoritmo 2.

Assim, o algoritmo *Q-learning*, abordado na seção 3.1, tem como função selecionar de forma autônoma a melhor ação a ser executada em sessão de aprendizagem. Isso significa que será escolhida a CEA com maior probabilidade de ocorrência, a preferida do estudante (DORÇA, 2012).

3.3.4 Processo Estocástico de Simulação de Desempenho do Estudante

Ao desenvolver um trabalho científico a partir do qual uma nova abordagem acerca de um assunto é apresentada, o autor deve submeter a sua proposta a testes no intuito de apresentar suas contribuições e defendê-las através de resultados que comprovem a eficiência da abordagem.

Algoritmo 2 Algoritmo *Q-learning* aplicado à modelagem automática e dinâmica de EAs proposto por Dorça (2012)

```

1: Inicialize o ME;
2: enquanto  $s$  não seja o estado final faça
3:   Selecione um conceito  $C$  a ser apresentado ao estudante;
4:   Selecione, através do MP, uma CEA  $a$ ;
5:   Execute  $a$ , apresentando adequadamente os objetos de aprendizagem que ensinam
      o conceito  $C$  ao estudante;
6:   Avalie a performance do estudante no conceito  $C$ ;
7:   Atualize o estado cognitivo do estudante no ME em relação a  $C$ ;
8:   Receba a recompensa  $r$ , dada por  $PFM$ ;
9:   Calcule o reforço  $R$  de acordo com a Equação 3.4;
10:  Atualize os  $EA_p$  através de  $R1$  e  $R2$ ;
11:  Faça de  $s$  o próximo estado, dado por  $s'$ ;
12: fim enquanto

```

Em diversas áreas do conhecimento, esses testes são feitos através da observação, em outros trabalhos é necessária a criação de modelos que simulem situações reais, o que se justifica por meio de diversos fatores: tempo, recursos, complexidade, dentre outros. Na área computacional, é comum identificar modelos de simulação, os quais são utilizados como ferramentas para a experimentação.

Em seu trabalho, Dorça (2012) propõe um modelo que simula o processo de aprendizagem de estudantes, o qual leva em consideração os EAs do estudante e seu estado cognitivo acerca dos conceitos apresentados, e avalia o seu desempenho após cada sessão de aprendizagem, fornecendo um resultado PFM tal que $0 \leq PFM \leq 100$.

Seguindo o raciocínio dos estudos feitos acerca de sistemas inteligentes voltados para a educação, tais como Iglesias et al. (2009a), Iglesias et al. (2009b), Graf, Kinshuk e Ives (2010), Dorça et al. (2011), Dorça (2012), Kara e Sevim (2013) e Gonçalves (2015), tal modelo contempla a proposta de fornecer uma melhor experiência aos estudantes durante o processo de aprendizagem, buscando maximizar seu desempenho ao final do processo.

O PESDE sabe quais são os Estilos de Aprendizagem reais do estudante, porém não sabe nada a respeito dos EAs armazenados no ME, em outras palavras, o PESDE desconhece os EA_p . Outro ponto interessante é o fato de ele considerar a força das preferências do estudante para cada dimensão do FSLSM que, segundo Graf, Liu e Kinshuk (2008), tem grande influência no desempenho do estudante quando não são satisfeitas. De acordo com seus estudos, quando escolhidas estratégias inadequadas para estudantes com preferências fortes, esses apresentaram desempenhos inferiores aos desempenhos de obtidos por estudantes de preferências moderada e leve, quando essas não coincidiam com a estratégia adotada. Os resultados apresentados por Graf, Liu e Kinshuk (2008) são confirmados por Kinshuk, Liu e Graf (2009) que afirmam que preferências fortes não satisfeitas impactam de forma significativa no desempenho do estudante.

Como forma de representar tais conceitos, o PESDE calcula a Q_{PNS} , que

corresponde à Quantidade de Preferências Não Satisfeitas identificadas pelo sistema na CEA selecionada. Diante disso, Dorça (2012) desenvolveu uma forma de atribuir maior peso às preferências fortes não satisfeitas no cálculo da Q_{PNS} . Isso foi feito da seguinte forma: o sistema verifica se houve alguma preferência forte não satisfeita, caso haja, ao resultado do cálculo da Q_{PNS} o PESDE adiciona 1; se não houver nenhuma preferência forte não satisfeita, o PESDE verifica se houve alguma preferência moderada não satisfeita, caso haja ao resultado do cálculo da Q_{PNS} o sistema adiciona 0,5, o que faz com que $0 \leq Q_{PNS} \leq 5$.

Outro fator importante que afeta o cálculo da performance do estudante é o fator aleatório, característica determinante do processo estocástico, que é o processo de aprendizagem. Inserir um valor aleatório no cálculo da performance Dorça (2012) garante que não só EAs influenciam no desempenho, mas também outros fatores inerentes ao sistema. Esses fatores, que modelam a incerteza do processo, são representados por β , de modo que seu valor é definido aleatoriamente ao final de cada sessão de aprendizagem, tal que $0 \leq \beta \leq 1$.

A Equação 3.5 descreve o cálculo do desempenho, ou performance PFM :

$$PFM = 100 - (Q_{PNS} \times K \times \beta) \quad (3.5)$$

Por fim, o último elemento que compõe o cálculo do desempenho do estudante é uma constante, K , definida por Dorça (2012), cujo valor é 20. O valor dessa constante ajusta a equação para manter seu segundo termo e, conseqüentemente, a nota do estudante entre 0 e 100.

Dorça utilizou o PESDE para gerar dados que permitissem que fosse feita uma análise estatística a respeito do desempenho do algoritmo proposto por ele. Diante disso, a intenção é utilizar na presente abordagem o mesmo sistema de simulação para que seja possível obter dados da mesma forma que o autor, no intuito de desenvolver análises estatísticas e, posteriormente, comparar os resultados finais com os resultados finais encontrados por Dorça (2012).

3.4 Média Móvel Exponencialmente Ponderada

A ideia de Média Móvel Exponencialmente Ponderada (MMEP) surgiu em um ambiente empresarial, em que gerentes discutiam as vendas realizadas nas últimas semanas e as vendas a serem feitas nas próximas. A partir da discussão sobre as vendas, foi levantada a seguinte questão: como estimar a produção para as próximas semanas? (BOX; HUNTER; HUNTER, 2005).

Dessa dúvida, surgiu a necessidade de analisar o histórico de vendas e produção para que fosse estimada a quantidade ideal, ou pelo menos próxima do ideal, a ser pro-

duzida, de modo que não houvesse desperdício, muitos produtos não vendidos, ou perda na receita, demanda superior à quantidade produzida.

A princípio, uma possível solução seria analisar a média ponderada das duas informações, vendas e produção. Contudo, as vendas podem sofrer grandes variações em função de fatores sobre os quais a empresa produtora não tem controle. Por exemplo, uma empresa que produz artigos natalinos tende a produzir mais quando o período natalino se aproxima, pois as vendas tendem a aumentar nesse período.

Considerando essa possível variação, a média ponderada não seria capaz de estimar com precisão a quantidade a ser produzida, pois em seu cálculo todos os valores que compõem o histórico têm a mesma relevância.

Ao contrário de como acontece no cálculo da média ponderada, o cálculo da MMEP utiliza um fator de suavização que possibilita que a pessoa que está desenvolvendo o cálculo defina se os dados antigos merecem maior ou menor relevância, conforme é possível perceber na equação 3.6, adaptada de Spagnol (2011):

$$\hat{y}_{t+1} = \lambda y_t + \theta \hat{y}_t \quad (3.6)$$

Na equação 3.6, λ representa o complementar do fator de suavização θ , isto é, $1 - \theta$. Tem-se, ainda, \hat{y}_{t+1} como a previsão que se deseja obter (MMEP atual), y_t como o resultado encontrado no momento (nota do estudante ao final da sessão de aprendizagem) e \hat{y}_t como a previsão calculada anteriormente (MMEP calculada no momento anterior).

Obter um valor ótimo para o fator de suavização não é uma tarefa simples. Segundo Box, Hunter e Hunter (2005), o valor desse fator varia de série para série, ou seja, cada situação exige um valor diferente.


Além disso, o fator de suavização é o elemento que define a velocidade de reação do cálculo, conforme afirmam Awheda e Schwartz (2013). O que significa que, dependendo do valor especificado para o fator de suavização, a equação pode fornecer resultados com alterações abruptas ou não (BOX; HUNTER; HUNTER, 2005).

Essa afirmação também é defendida por Montgomery e Runger (2009), que argumentam que o fator de suavização é que determina o compromisso entre a redução de ruído, que no caso desta abordagem consistem em fatores aleatórios externos ao controle da aplicação, e a resposta a uma mudança na média. Segundo Box, Hunter e Hunter (2005), quanto maior o seu valor, mais suave são os resultados.

A Figura 10, na página 70, adaptada de Box, Hunter e Hunter (2005), mostra três gráficos com resultados da aplicação de MMEP com diferentes valores do fator de suavização.

A partir dos gráficos da Figura 10, pode-se perceber que quanto menor o valor do fator de suavização, mais abrupta é a mudança entre os resultados. Isso é evidenciado pela diferença entre os tamanhos das barras, que é maior para $\theta = 0,4$.

Figura 10 – Resultados de aplicações de MMEP com os respectivos valores para o fator de suavização $\theta = 0,4$; $\theta = 0,6$ e $\theta = 0,8$



Fonte – (BOX; HUNTER; HUNTER, 2005). Adaptado.

Os próprios Box, Hunter e Hunter (2005) apresentam como possível solução para a definição do valor de θ , a utilização do erro entre a previsão e o resultado real obtido, cuja ideia é minimizar a soma dos quadrados dos erros. Essa redução, pode ser calculada por meio da equação 3.7:

$$EQM = \sum_{i=1}^{i=t} (y_t - \hat{y}_t)^2 \quad (3.7)$$


O funcionamento da equação consiste no somatório de todos os erros de previsão elevados ao quadrado. Um erro de previsão é dado pela diferença entre o valor previsto pelo modelo, para um instante (y_t), e o valor estimado para o mesmo instante (\hat{y}_t). A Figura 11 (ver página 71) representa o comportamento da MMEP em um gráfico exemplo.

No gráfico da Figura 11, a curva de cor azul representa os dados reais e a curva de cor alaranjada representa os dados obtidos a partir do cálculo da MMEP.

É possível perceber que, diferente da média ponderada, a MMEP não é uma equação linear. Ela acompanha a tendência, o que permite a realização de estimativas mais precisas para esse caso, quando comparada com a média ponderada. Nota-se, também, uma oscilação menor da curva que representa a MMEP dos dados reais, quando comparada com a curva desses dados.

De acordo com Awheda e Schwartz (2013), MMEP é uma ferramenta utilizada para realizar análises sobre dados oriundos de séries temporais. Box, Hunter e Hunter

Figura 11 – Gráfico que mostra o efeito de suavização obtido através da aplicação de MMEP



(2005) destacam alguns pontos em favor desse método, tais como sua robustez, a facilidade do seu cálculo e o fato de proporcionar certo grau de relevância aos dados utilizados nele.

Os autores ainda evidenciam sua grade utilidade na área industrial, na qual é utilizada, com frequência, no monitoramento e no ajuste de processos que fazem parte do controle estatístico de processos de produção. O monitoramento consiste em detectar pontos que podem representar falhas no sistema, ao passo que o ajuste consiste em compensar possíveis variações no sistema.

Com uma proposta diferente, Fehlmann e Kranich (2014) abordam a MMEP, juntamente com gráficos de controle Q , para monitorar e controlar processos de desenvolvimento de *softwares*. A abordagem apresentada pelos autores permite que sejam previstas situações que podem levar a eventos não controlados, os quais podem prejudicar o processo.

Em 2015, Lu, Tsai e Chen (2015) desenvolveram um trabalho no qual o conceito de MMEP é implementado em um algoritmo capaz de detectar violações da qualidade de serviço. Os testes da abordagem foram aplicados sobre conjuntos de dados reais, obtidos de serviços que permitem a comunicação entre sistemas distintos através da Internet, conhecidos como *web-services*. Na oportunidade, o desempenho do algoritmo que implementa a MMEP foi comparado com o desempenho de um algoritmo que implementa outra técnica estatística de previsão, conhecida como CUSUM. Como resultado, os autores chegaram à conclusão de que o algoritmo que utiliza MMEP é capaz de identificar as violações de qualidade de serviço de forma mais rápida quando comparado ao que utiliza CUSUM.

Também na área da tecnologia, Silva et al. (2017) avaliam desempenhos de algoritmos que fazem o balanceamento de carga em redes de computadores. Os algoritmos

avaliados implementam as seguintes políticas de balanceamento de carga em redes de computadores definidas por *software*: *round robin*, *random*, *txbytes*, *cpuq-load* e *load/load-prev*. Dentre essas políticas, *load* e *load-prev* utilizam o conceito de MMEP para estimar, estatisticamente, a carga média dos servidores.

O conceito de Média Móvel Exponencialmente Ponderada é utilizado com frequência nas áreas de engenharias, finanças e computação, porém, até o momento, não foram encontrados trabalhos que abordam esse conceito no âmbito educacional, especificamente na modelagem de sistemas de detecção automática de EAs. Esse fato destaca a importância do trabalho aqui desenvolvido, no sentido de aprimorar abordagens já existentes e melhorar o processo de aprendizagem na Educação a Distância.

De maneira a aprimorar o processo de detecção de EAs proposto por Dorça (2012), o conceito de MMEP pode ser utilizado pelo CME, como parâmetro adicional, no processo de decisão sobre a aplicação de ajustes nos EAs Probabilísticos. Isso porque, a verificação, considerando apenas o desempenho do estudante, pode induzir o CME a tomar decisões erradas, uma vez que fatores aleatórios podem exercer influência sobre essa performance. Nesse sentido, por meio de decisões mais precisas, ajustes desnecessários no ME podem ser evitados, garantindo a manutenção das probabilidades de estratégias consideradas, até então, adequadas.

4 METODOLOGIA

O presente trabalho caracteriza-se como uma pesquisa quantitativa, cujos resultados são quantificados por meio de recursos matemáticos e estatísticos. Os dados analisados nesta proposta são provenientes de simulação computacional, portanto não se trata de uma pesquisa aplicada em um AVA real. Além disso, esta proposta caracteriza-se por ser experimental, tendo início a partir das formulações do problema e de uma hipótese. Em seguida, são aplicados tratamentos diferentes aos grupos avaliados, de modo que cada tratamento, neste trabalho, refere-se às duas abordagens simuladas: aquela proposta por Dorça (2012) e a que utiliza o conceito de Média Móvel Exponencialmente Ponderada. Por fim, análises são feitas sobre os dados obtidos a partir da etapa anterior, os quais permitem a aceitação ou a rejeição da hipótese formulada (GERHARDT; SILVEIRA, 2009).

Conforme discutido anteriormente, o presente trabalho apresenta como proposta a utilização do conceito de Média Móvel Exponencialmente Ponderada (MMEP) como recurso na busca por melhores resultados dos que os obtidos por Dorça (2012). Para isso, o CME e o MP apresentados por Dorça (2012) passarão por modificações, de modo que o funcionamento do CME passará a levar em consideração a MMEP dos desempenhos obtidos pelo estudante para cada estratégia pedagógica selecionada nas sessões de aprendizagem anteriores. Além disso, a taxa de aprendizagem do agente, utilizada no momento de atualização do Modelo do Estudante, deixará de ser um valor fixo e passará a ser calculada em função do rendimento do aluno ao final da sessão de aprendizagem.

A metodologia deste trabalho é dividida em Metodologia de desenvolvimento, descrita na seção 4.1 e Metodologia de experimentação, detalhada na seção 4.2. A primeira descreve os métodos adotados para o desenvolvimento do modelo e a segunda descreve os métodos utilizados em sua experimentação.

4.1 Metodologia de desenvolvimento

Conforme afirmação de Popescu (2009), reforçada por Feldman, Monteserin e Amandi (2015), a detecção automática de estilos de aprendizagem que faz uso das informações presentes no ME pode ser feita de forma explícita ou de forma implícita. No presente trabalho, será abordado o método implícito, a partir do qual a modelagem e, conseqüentemente, a detecção dos EAs do estudante será feita com base em técnicas de IA.

Segundo Popescu (2009), a modelagem implícita pode ser realizada com base em 3 informações distintas: no desempenho do estudante, no seu comportamento ao interagir com o sistema ou nas respostas fornecidas por ele próprio. A modelagem do

estudante nesta proposta é feita com base no seu desempenho, diferente da maioria dos trabalhos, em que o comportamento do estudante dentro do ambiente de aprendizagem é levado em consideração.

A nota do estudante foi escolhida como parâmetro para a modelagem devido a alguns fatores. Primeiramente, a nota é o elemento que indica com maior precisão o quão adequada é a estratégia pedagógica adotada. Além disso, é um parâmetro fácil de ser obtido e capaz de representar a principal característica do processo de aprendizagem, o não determinismo, conforme aponta Dorça (2012), pois, a nota do estudante ao final de uma sessão independe das notas de sessões de aprendizagem anteriores.

Um dos objetivos deste trabalho, conforme apresentado no capítulo de introdução, é aprimorar o método proposto por Dorça (2012) através da redução do número de sessões de aprendizagem necessárias para que o sistema identifique os EAs do estudante. Essa redução concentra-se sobre as sessões de aprendizagem desnecessárias a que é submetido o estudante quando seu desempenho cai devido a fatores externos.

Com arquitetura semelhante à arquitetura de um STI e à proposta por Dorça (2012), o sistema aqui proposto teve seu desenvolvimento dividido em módulos, de modo que cada módulo tem uma função específica e bem definida dentro do sistema. Entre os módulos, ocorre a troca de informações, de maneira que o resultado de atividades executadas por um desses módulos é tido como entrada para que o outro execute suas atividades.

Diante da grande consistência do ME e do MP elaborados por Dorça (2012), esta abordagem procura manter as principais características desses elementos, concentrando um maior esforço no CME e em alguns ajustes no MP. Além disso, o método de simulação será o PESDE, também proposto por Dorça (2012).

4.1.1 Modelo do Estudante

Conforme apresentado na seção 2.5.1, o ME é responsável por armazenar informações que permitam ao sistema fazer inferências acerca do estudante. No caso desta proposta, as informações presentes no ME consistem nos EAs probabilísticos do estudante, nos conceitos a serem vistos pelo estudante e no seu nível de conhecimento acerca de cada um desses conceitos.

Para Brusilovsky e Millán (2007) o ME, no caso específico de sistemas adaptativos voltados para ambientes educacionais, é fundamental para o desenvolvimento desse tipo de sistema, pois armazena informações específicas do estudante, o que permite que o sistema forneça adaptatividade a partir das informações individuais do usuário.

Com base nos trabalhos de Franzoni et al. (2008) e Franzoni e Assar (2009), os EAs probabilísticos são definidos no ME como grupos chamados CEAs. Esses grupos representam combinações dos EAs do FSLSM, de modo que cada um deles é sempre definido por 1 EA de cada dimensão do modelo. Assim, tem-se ao todo 16 CEAs (2^4).

Mantendo a característica de probabilidade de ocorrência dos EAs proposta por Dorça (2012), os EAs presentes no ME são representados por meio dessas probabilidades. Sabendo que os EAs de uma dimensão são complementares entre si, a soma das probabilidades de ocorrência desses 2 EAs é sempre igual a 1. Dessa forma, se a probabilidade de ocorrência do EA Ativo é igual a 0,90, a probabilidade de ocorrência do EA Reflexivo é, obrigatoriamente, igual a 0,10.

Ciente dessa característica e sabendo que nesta abordagem é possível tanto a detecção quanto a correção dos EAs probabilísticos, é possível definir inicialmente os EAs probabilísticos com base nos resultados da aplicação do ILS, detalhado na seção 2.1.2.1. Fazendo isso, a probabilidade de ocorrência de um determinado EA é dada pela quantidade de respostas que tendem para esse EA dividido pela quantidade total de questões para a dimensão a que pertence o EA. Considerando a dimensão Entrada do FSLSM, por exemplo, se o estudante respondeu a 6 questões tendendo para o EA Visual e 5 questões tendendo para o EA Verbal, a representação matemática do cálculo da probabilidade de ocorrência desses estilos é dado respectivamente por:

$$\begin{aligned} Prob_{(Visual)} &= \frac{6}{11} = 0,55 \\ \text{e} \\ Prob_{(Verbal)} &= \frac{5}{11} = 0,45 \end{aligned}$$

Dessa forma os EAs probabilísticos da dimensão Entrada no ME podem ser representados pela Tabela 3:

Tabela 3 – EAs Probabilísticos da dimensão Entrada

EAs Probabilísticos	
Entrada	
Visual	Verbal
0,55	0,45


Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

Caso não seja aplicado o ILS para saber os EAs do estudante, o ME é inicializado a partir da atribuição da probabilidade 0,50 para cada EA, que significa que não se tem conhecimento nenhum sobre os EAs do estudante e o sistema terá a missão de fazer essa identificação.

O nível de conhecimento ou Estado Cognitivo do estudante sobre cada conceito a ser visto é modelado no ME de acordo com a Taxonomia de Bloom, detalhada na seção 2.2 e representada graficamente pela Figura 12 (ver página 76). Como essa taxonomia é composta por 6 níveis, no ME o nível de conhecimento do estudante sobre um conceito varia de 0 a 5, em que 0 (equivalente ao nível Conhecimento na pirâmide) significa que

o estudante não possui conhecimento algum sobre o conceito e 5 (equivalente ao nível Avaliação na pirâmide) é o nível de conhecimento máximo.

Figura 12 – Pirâmide hierárquica que apresenta os níveis da Taxonomia de Bloom



Por fim, o último elemento que compõe o ME são os objetivos de aprendizagem. Esses elementos representam o conteúdo a ser estudado e variam de acordo com a ementa do curso. Devido a essa possibilidade de variação, esse é um parâmetro que pode ser definido antes da primeira sessão de aprendizagem do estudante. Ele é que define quantos conceitos o estudante deve aprender ao longo do curso ou processo de aprendizagem.

Considerando que a probabilidade de ocorrência dos EAs são dadas pelas seguintes equações:

$$\begin{aligned}
 Prob_{(Ativo)} = Prob_{(Sensitivo)} = Prob_{(Sequencial)} = Prob_{(Visual)} &= \frac{6}{11} = 0,55 \\
 &e \\
 Prob_{(Reflexivo)} = Prob_{(Intuitivo)} = Prob_{(Global)} = Prob_{(Verbal)} &= \frac{5}{11} = 0,45
 \end{aligned}$$

O ME pode ser representado pela Tabela 4.

Tabela 4 – Modelo do Estudante

Estilos de Aprendizagem Probabilísticos							
Processamento	Percepção	Entrada		Organização			
0,55	0,45	0,55	0,45	0,55	0,45	0,55	0,45
Objetivos de Aprendizagem e Estado Cognitivo							
$OA = \{\langle C_0, 5 \rangle \cdots \langle C_{n-1}, 5 \rangle\}$							
$EC = \{\langle C_0, -1 \rangle \cdots \langle C_{n-1}, -1 \rangle\}$							

Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

4.1.2 Módulo Pedagógico

Escolher estratégias pedagógicas em um processo de aprendizagem pode ser mais complexo do que parece, pois o sucesso desse processo depende fortemente delas.

Nesta abordagem, estratégias pedagógicas consistem na forma como o conteúdo é apresentado ao estudante. Portanto, estratégias pedagógicas adequadas aos EAs do aluno podem fazer com que o estudante tenha uma aprendizagem de qualidade e rápida. Porém, essa não é uma tarefa simples, aliás, é o principal motivo deste trabalho.

Escolher estratégias adequadas depende do conhecimento que se tem do usuário. É por isso que o ME é tão importante, a partir das informações coletadas do estudante ele dará suporte ao Módulo Pedagógico (MP) para que esse último selecione a melhor estratégia pedagógica para aquele estudante. Assim, a função do MP é escolher, dentre as possíveis estratégias pedagógicas, aquela que melhor se aplica às características e preferências do usuário, inferidas pelo sistema.

O FSLSM, modelo de Felder e Silverman discutido na seção 2.1.2, apresenta as possíveis preferências que uma pessoa tem de receber e processar a informação, chamadas de Estilos de Aprendizagem (EAs). De acordo com o modelo existem ao todo 8 EAs distribuídos em 4 dimensões, de modo que cada dimensão possui 2 EAs opostos entre si. Cada dimensão aborda a informação em um sentido específico, captar, processar, organizar ou perceber. Contudo, o recebimento e processamento da informação é composto da combinação desses sentidos, ou seja, do início ao fim desse processo a informação passa por todos os sentidos como se eles fossem etapas. Dessa forma surge o conceito discutido por Franzoni et al. (2008) e Franzoni e Assar (2009), a Combinação de Estilos de Aprendizagem (CEA).

De maneira a tratar a aprendizagem como um processo completo, o MP aqui proposto aborda as estratégias pedagógicas como uma combinação das preferências do estudante para cada dimensão do FSLSM. Portanto, quando se tratar de EAs do estudante, o MP considerará uma combinação de 4 EAs do FSLSM. Assim sendo, existem 16 tipos de estudantes e um estudante só se enquadra em um dos 16 tipos.

Conforme apresentado na seção 4.1.1, os EAs do estudante são representados por probabilidades no ME. Isso implica que, como o MP é o responsável por identificar os EAs do estudante, ele fará as inferências sobre tais preferências com base nas probabilidades presentes no ME. Essa função é atribuída a ele para que a escolha da forma de apresentação do conteúdo seja feita de forma a facilitar a aprendizagem do estudante.

Como esse é um modelo probabilístico e não determinístico, a probabilidade de o estudante preferir cada EA é dada por Cadeias de Markov (CM) e armazenada no ME. Assim, são necessárias 4 CM para realizar os cálculos das probabilidades de todos os EAs, sendo cada cadeia associada a uma dimensão do FSLSM. Com base nisso, o tipo de estudante, representado por sua CEA, é inferido estocasticamente pelo MP com base nas probabilidades de ocorrência de cada EA que o compõe. Essa inferência é dada pela multiplicação das probabilidades de ocorrência dos EAs encontradas no ME. A Equação

4.1 representa o cálculo da probabilidade de ocorrência de cada CEA:

$$Prob_{CEA} = Prob_{EA1} \times Prob_{EA2} \times Prob_{EA3} \times Prob_{EA4} \quad (4.1)$$

Considerando os valores armazenados na Tabela 4, que representa o ME na sessão anterior, o cálculo da CEA composta pelos EAs Ativo, Intuitivo, Verbal e Global é feito da seguinte forma:

$$Prob_{(Ati,Int,Ver,Glo)} = Prob_{(Ati)} \times Prob_{(Int)} \times Prob_{(Ver)} \times Prob_{(Glo)}$$

$$Prob_{(Ati,Int,Ver,Glo)} = 0,55 \times 0,45 \times 0,45 \times 0,45 = 0,050$$

A estratégia que melhor atende às preferências do estudante é aquela cujo produto dos seus EAs é o maior dentre os demais. Portanto, o MP realiza o cálculo das probabilidades de todas as estratégias pedagógicas para depois escolher aquela com a maior probabilidade de ocorrência. Ainda tomando como base o ME definido na sessão anterior, a tabela de probabilidades construída pelo MP, fundamental para que seja escolhida a melhor estratégia pedagógica, seria semelhante à Tabela 5.

Tabela 5 – Cálculo das probabilidades das CEAs

CEA	Probabilidade
$CEA = \{Ati, Sen, Vis, Seq\}$	$Prob = 0,55 \times 0,55 \times 0,55 \times 0,55 = 0,092$
$CEA = \{Ati, Sen, Vis, Glo\}$	$Prob = 0,55 \times 0,55 \times 0,55 \times 0,45 = 0,075$
$CEA = \{Ati, Sen, Ver, Seq\}$	$Prob = 0,55 \times 0,55 \times 0,45 \times 0,55 = 0,075$
$CEA = \{Ati, Sen, Ver, Glo\}$	$Prob = 0,55 \times 0,55 \times 0,45 \times 0,45 = 0,061$
$CEA = \{Ati, Int, Vis, Seq\}$	$Prob = 0,55 \times 0,45 \times 0,55 \times 0,55 = 0,075$
$CEA = \{Ati, Int, Vis, Glo\}$	$Prob = 0,55 \times 0,45 \times 0,55 \times 0,45 = 0,061$
$CEA = \{Ati, Int, Ver, Seq\}$	$Prob = 0,55 \times 0,45 \times 0,45 \times 0,55 = 0,061$
$CEA = \{Ati, Int, Ver, Glo\}$	$Prob = 0,55 \times 0,45 \times 0,45 \times 0,45 = 0,050$
$CEA = \{Ref, Sen, Vis, Seq\}$	$Prob = 0,45 \times 0,55 \times 0,55 \times 0,55 = 0,075$
$CEA = \{Ref, Sen, Vis, Glo\}$	$Prob = 0,45 \times 0,55 \times 0,55 \times 0,45 = 0,061$
$CEA = \{Ref, Sen, Ver, Seq\}$	$Prob = 0,45 \times 0,55 \times 0,45 \times 0,55 = 0,061$
$CEA = \{Ref, Sen, Ver, Glo\}$	$Prob = 0,45 \times 0,55 \times 0,45 \times 0,45 = 0,050$
$CEA = \{Ref, Int, Vis, Seq\}$	$Prob = 0,45 \times 0,45 \times 0,55 \times 0,55 = 0,061$
$CEA = \{Ref, Int, Vis, Glo\}$	$Prob = 0,45 \times 0,45 \times 0,55 \times 0,45 = 0,050$
$CEA = \{Ref, Int, Ver, Seq\}$	$Prob = 0,45 \times 0,45 \times 0,45 \times 0,55 = 0,050$
$CEA = \{Ref, Int, Ver, Glo\}$	$Prob = 0,45 \times 0,45 \times 0,45 \times 0,45 = 0,041$
Soma das probabilidades = 1,000	

Fonte – (DORÇA et al., 2011; DORÇA, 2012). Adaptado.

Como este trabalho utiliza o conceito de MMEP, além de armazenar as probabilidades de seleção de cada estratégia pedagógica, o MP mantém, para cada estratégia

pedagógica, a MMEP dos desempenhos obtidos pelo estudante quando a respectiva estratégia foi selecionada. Assim, MP é capaz de fornecer informações ao CME, cuja estrutura e funcionamento serão detalhados na seção seguinte, para que esse decida e aplique, caso necessário, modificações no ME.

Dessa forma, ao final de cada sessão de aprendizagem, o desempenho do estudante é coletado pelo MP, que automaticamente calcula, considerando a estratégia pedagógica selecionada, a MMEP dos desempenhos obtidos quando tal estratégia foi selecionada. A Tabela 6 representa o MP aqui desenvolvido.

Tabela 6 – Representação do Módulo Pedagógico proposto neste trabalho

Módulo Pedagógico		
CEA	Probabilidade de seleção	MMEP
$CEA_1 = \{Ati, Sen, Vis, Seq\}$	0,092	89
$CEA_2 = \{Ati, Sen, Vis, Glo\}$	0,075	81
$CEA_3 = \{Ati, Sen, Ver, Seq\}$	0,075	73
$CEA_4 = \{Ati, Sen, Ver, Glo\}$	0,061	62
$CEA_5 = \{Ati, Int, Vis, Seq\}$	0,075	62
$CEA_6 = \{Ati, Int, Vis, Glo\}$	0,061	38
$CEA_7 = \{Ati, Int, Ver, Seq\}$	0,061	81
$CEA_8 = \{Ati, Int, Ver, Glo\}$	0,050	0
$CEA_9 = \{Ref, Sen, Vis, Seq\}$	0,075	73
$CEA_{10} = \{Ref, Sen, Vis, Glo\}$	0,061	27
$CEA_{11} = \{Ref, Sen, Ver, Seq\}$	0,061	55
$CEA_{12} = \{Ref, Sen, Ver, Glo\}$	0,050	0
$CEA_{13} = \{Ref, Int, Vis, Seq\}$	0,061	43
$CEA_{14} = \{Ref, Int, Vis, Glo\}$	0,050	0
$CEA_{15} = \{Ref, Int, Ver, Seq\}$	0,050	0
$CEA_{16} = \{Ref, Int, Ver, Glo\}$	0,041	0

Percebe-se na representação do MP através da Tabela 6 alguns valores de MMEP iguais a 0. Isso pode acontecer para os casos em que a respectiva estratégia pedagógica não foi selecionada nenhuma vez durante o processo de aprendizagem.

Excetuando-se o valor 0, também existem na representação valores acima e abaixo de 60, que é o desempenho mínimo exigido pelo sistema. É com base nesses valores que o CME tomará a decisão de modificar ou não os EAs Probabilísticos presentes no ME.

4.1.3 Componente de Modelagem do Estudante

Conforme mencionado anteriormente, o sucesso de um sistema de detecção e correção dos EAs Probabilísticos depende fortemente da forma como esse sistema realiza a modelagem do estudante. Assim, a precisão da modelagem é que determinará sua eficiência.

Como o foco deste trabalho é fazer com que a detecção e a correção dos EAs Probabilísticos do estudante seja feita de forma mais rápida e precisa, as principais contribuições se concentram no Componente de Modelagem do Estudante (CME), que é o elemento responsável por realizar as inferências sobre as preferências do estudante, armazenando-as no ME.

Em seu trabalho, Dorça (2012) utiliza a Aprendizagem por Reforço (AR) para realizar tais inferências. Nele os ajustes são feitos sempre que uma deficiência no processo de aprendizagem é detectada. Contudo, conforme já apontado, o processo originalmente idealizado pelo autor pode promover ajustes desnecessários no ME. Eles, por sua vez, podem desviar o foco do algoritmo ocasionando atrasos no processo de detecção e correção dos EAs.

Como alternativa para eliminar essa deficiência, foi proposto um novo algoritmo, também baseado em AR, sendo esse reforço foi ajustado para evitar a ocorrência de tais modificações desnecessárias. Esse algoritmo, variação do *Q-learning*, é o núcleo do CME desta proposta.

Essa abordagem faz-se necessária porque nem sempre o mal desempenho do estudante ao final de uma sessão de aprendizagem é reflexo de falhas na escolha das estratégias pedagógicas. Muitas vezes, as causas dessa deficiência no processo de aprendizagem podem ser outros fatores. Exemplos desses fatores são o estado emocional do estudante, seu estado de saúde, o ambiente onde ele estuda etc. Isso significa que nem sempre que um estudante obtiver um desempenho abaixo do desejado é necessário modificar o ME. Assim, ao invés de se aplicar reforços conforme proposto por Dorça, o sistema analisará o histórico de desempenhos obtidos quando foi selecionada a estratégia pedagógica em questão. Somente a partir dessa análise é que o sistema decidirá se é necessário ajustar o ME ou não.

O CME pode ser considerado o elemento central do sistema aqui proposto. A prova disso é que ele tem acesso a informações dos demais componentes do sistema. Coletando informações do ME e do MP, o CME processa essas informações e, caso necessário, promove modificações no ME. Essas modificações são feitas por meio de AR.

Como bem destacado por Dorça (2012), a AR apresenta o seguintes elementos:

- Conjunto de estados;
- Conjunto de ações;
- Percepção do ambiente;
- Reforço;
- Função ganho.

Cada um desses elementos é representado nesta abordagem como elementos integrantes do processo de aprendizagem. Por exemplo, o conjunto de estados pode ser

representado pelas probabilidades de ocorrência de cada EA presentes no ME. O conjunto de ações, por sua vez, é representado pelas estratégias pedagógicas ou CEAs, que definem como o conteúdo deve ser apresentado ao estudante. A percepção do ambiente é feita por meio de avaliações de desempenho e por uma avaliação do histórico de desempenhos obtidos em todas as ocasiões em que foi utilizada a estratégia selecionada. O reforço é dado por uma função que leva em consideração os resultados obtidos a partir da percepção do ambiente, o estado atual do sistema e a ação utilizada. Por fim, a função ganho define a utilidade de uma estratégia pedagógica (CEA) considerando o estado do sistema (ME).

Dessa forma, o funcionamento do CME tem início com a observação do ambiente. Esta etapa consiste na coleta de algumas informações como:

- as preferências do estudante, representadas pelas probabilidades de preferência pelos EA_p ;
- o desempenho obtido pelo estudante ao final da sessão de aprendizagem; e
- a estratégia pedagógica utilizada naquela sessão.

Uma vez obtidas as informações necessárias, o CME calcula a MMEP dos desempenhos obtidos pelo estudante quando essa CEA foi utilizada. Isso é feito com base na Equação 3.6 (ver página 69), uma vez adaptada para o contexto aqui apresentado.

Como esse cálculo exige informações geradas em sessões de aprendizagem anteriores, ao final de cada sessão de aprendizagem, o desempenho obtido pelo estudante é armazenado na estratégia pedagógica selecionada, conforme representação na Tabela 6 (ver página 79). Isso permite a manutenção do histórico de desempenhos nas sessões de aprendizagem em que aquela CEA foi selecionada, o que, por sua vez, facilita o cálculo.

Assim, adaptando a referida equação ao contexto aqui apresentado, o cálculo é feito com base na MMEP calculada na sessão de aprendizagem anterior e no desempenho gerado na atual sessão de aprendizagem. O seu resultado, juntamente com a nota obtida pelo estudante, são parâmetros utilizados pelo CME para decidir se é necessária ou não a aplicação de ajustes no ME.

Isso permite que, ao final da sessão de aprendizagem, mesmo que o estudante tenha obtido um desempenho ruim na atual sessão, o resultado da MMEP pode ser superior ao mínimo exigido pelo sistema, não obrigando o CME a ajustar as probabilidades presentes no ME.

Por outro lado, considerando que a CEA selecionada não possui um histórico de bons desempenhos e que o cálculo forneceu um resultado abaixo do mínimo exigido, o CME decide então ajustar o ME. Assim, para que ajustes sejam feitos no ME, tanto a nota do estudante quanto a MMEP de suas notas, quando utilizada a atual estratégia pedagógica, devem ser inferiores a 60. Esses ajustes consistem na alteração das probabilidades de ocorrência de todos EAs presentes no ME, de modo que aqueles presentes na

estratégia pedagógica selecionada têm sua probabilidade decrementada e os demais têm a sua probabilidade incrementada.

Isso é feito porque dentro de uma dimensão do FSLSM, os EAs a ela pertencentes são complementares entre si. Assim, a probabilidade de ocorrência de um é complementada pela probabilidade de ocorrência do outro, o que significa que a soma de suas probabilidades deve ser igual a 1. Portanto, considerando essa regra, se a probabilidade de um EA aumenta, a do seu complementar deve diminuir.

Conforme já mencionado, os ajustes no ME são realizados por meio de AR, portanto todos os ajustes nas probabilidades dos EA_p são realizados a partir de um sinal de reforço que, conforme propõe Dorça (2012), é calculado com base no desempenho do estudante e nas forças dos EAs inferidos pelo sistema. Em notação matemática, o cálculo do reforço é dado pela Equação 4.2.

$$R = \frac{1}{PFM \times DEA} \quad (4.2)$$

Na Equação 4.2, PFM corresponde ao desempenho obtido pelo estudante na sessão de aprendizagem atual e DEA representa a diferença entre os EA_p de uma mesma dimensão, calculada a partir da Equação 3.3 (ver página 66). A diferença entre os EAs representa a força das preferências do estudante. Dessa forma, quanto mais forte for a preferência do estudante, mais baixo é o sinal de reforço e mais difícil é a detecção de suas verdadeiras preferências.

Um ponto importante em sistemas que utilizam a AR é o valor da taxa de aprendizagem do agente, que é utilizada juntamente com o sinal de reforço para promover adequações no ambiente. Com valor pertencente ao intervalo $[0, 1]$, essa taxa tem grande influência sobre as mudanças realizadas, podendo fazer alterações muito profundas quando seu valor é grande e alterações muito sutis quando seu valor é pequeno demais (DORÇA, 2012).

Em seu trabalho, Dorça (2012) utiliza o valor 0,5 como taxa de aprendizagem do agente. Nesta proposta, diferente do que foi proposto por Dorça (2012), a taxa de aprendizagem do agente varia ao final de cada sessão de aprendizagem. Essa variação se deve ao cálculo da taxa, no qual é utilizada a nota obtida pelo estudante naquela sessão de aprendizagem. A Equação 4.3 representa o cálculo da taxa.

$$\alpha = 1 - \left(\frac{PFM}{100} \right) \quad (4.3)$$

Na equação 4.3, α representa a taxa de aprendizagem que se deseja obter, e PFM representa a performance do estudante ao final da sessão de aprendizagem.

Conforme citado no início desta seção, a presente proposta baseia-se no algoritmo de AR *Q-learning*, de modo que o objetivo é estimar, para determinado estado, a melhor ação, isto é, o melhor valor para $Q(s, a)$. Por se tratar de uma abordagem probabilística, a função de ganho, geralmente utilizada em algoritmos de AR, precisou ser

adaptada para que se adequasse à realidade aqui apresentada. Dessa forma, a equação que define a qualidade das estratégias pedagógicas levando em consideração as preferências do estudante é dada pela Equação 3.2 (ver página 66).

Assim, são necessários para realizar os ajustes no ME:

- o valor do reforço;
- a taxa de aprendizagem do agente;
- as probabilidades dos EAs presentes no ME.

Quando o estudante não obtém um resultado superior ou igual ao resultado mínimo exigido, considera-se que houve deficiência no processo de aprendizagem. Isso evidencia, teoricamente, uma deficiência no processo de escolha da estratégia pedagógica. Portanto, acredita-se que a estratégia pedagógica não é boa e que, conseqüentemente, sua probabilidade de ser selecionada deve ser reduzida.

Dessa forma, todos os EAs que compõem a CEA selecionada devem ter suas probabilidades decrementadas, ao passo que seus EAs complementares devem ter suas probabilidades incrementadas. Esse decremento deve ser feito com base no sinal de reforço multiplicado pela taxa de aprendizagem do agente.

Assim, a regra que define o ajuste dos EAs que compõem a CEA selecionada pode ser definida da seguinte forma:

$$EA_{d[i]} = EA_{d[i]} - \alpha \times R \quad (4.4)$$

Em que:

- $EA_{d[i]}$ representa o EA da dimensão $d[i]$ que compõe a CEA;
- α representa a taxa de aprendizagem do agente;
- R representa o sinal de reforço calculado com base na performance do estudante e na força dos EAs inferidos.

Por outro lado, os ajustes dos EAs complementares aos presentes na CEA podem ser dados pela diferença entre a probabilidade total (1) e as novas probabilidades dos EAs que compõem a CEA. Matematicamente esse cálculo pode ser representado da seguinte maneira:

$$EA_{d[i]}^C = 1 - EA_{d[i]}' \quad (4.5)$$

De modo que:

- $EA_{d[i]}^C$ representa o EA complementar ao EA da dimensão $d[i]$ presente na CEA selecionada;

- $EA'_{d[i]}$ representa o EA presente na CEA selecionada já com a sua probabilidade ajustada.

O funcionamento da ferramenta é apresentado através do Algoritmo 3 (ver página 84), sendo cada etapa apresentada de maneira bem definida.

Algoritmo 3 Algoritmo que utiliza MMEP e AR para detectar EAs

```

1: Inicializa o ME;
2: enquanto houver conceito a ser apresentado faça
3:   Selecione o conceito  $C$ ;
4:   Selecione, através do MP, uma CEA  $a$ ;
5:   Apresente o conteúdo considerando a estratégia pedagógica  $a$  selecionada;
6:   Avalie a performance  $PFM$  do estudante;
7:   se Existir  $MMEP$  dos desempenhos de  $a$  então
8:     Calcule a nova MMEP dos desempenhos de  $a$  ( $MMEP'$ );
9:     se  $PFM < 60$  então
10:      se  $MMEP' < 60$  então
11:        Calcule o sinal de reforço  $R$  conforme Equação 4.2 (ver página 82);
12:        Aplique os ajustes no ME de acordo com as regras definidas em 4.4 e
13:        4.5 (ver página 83);
14:        Faça  $MMEP$  receber o valor de  $MMEP'$ ;
15:        Repita o conceito  $C$ ;
16:      fim se
17:    senão
18:      Passe para o próximo conceito,  $C'$ ;
19:    fim se
20:  senão
21:    se  $PFM < 60$  então
22:      Calcule o sinal de reforço  $R$  conforme Equação 4.2 (ver página 82);
23:      Aplique os ajustes no ME de acordo com as regras definidas em 4.4 e 4.5
24:      (ver página 83);
25:      Faça  $MMEP$  receber o valor de  $PFM$ ;
26:      Repita o conceito  $C$ ;
27:    senão
28:      Passe para o próximo conceito,  $C'$ ;
29:    fim se
30:  fim se
31: fim enquanto

```

4.2 Metodologia de experimentação

A ferramenta proposta foi testada exaustivamente utilizando o simulador de desempenhos dos alunos (PESDE), de modo que tais testes ocorreram em etapas. Na primeira etapa, o objetivo foi obter o melhor valor para o coeficiente de suavização (θ). Isso foi necessário porque o valor desse parâmetro é elemento determinante para o sucesso da abordagem. Nela, o algoritmo aqui proposto foi testado com seu fator de suavização

variando entre 0,1 e 0,9, de modo que os resultados dessas execuções foram comparados apenas entre si. Uma vez identificado o melhor valor para θ , passou-se para a etapa seguinte, na qual os dois algoritmos, o aqui proposto e o apresentado por Dorça (2012), são executados com parâmetros iniciais iguais. Isso foi feito para que, ao final dos testes, os resultados fornecidos por eles pudessem proporcionar análises estatísticas comparativas entre os dois algoritmos. Essas análises permitiram verificar a eficiência do método aqui proposto.

4.2.1 Escolha do melhor valor para θ

Para cada valor de θ foi elaborado um conjunto de testes, no qual cada possível perfil de estudante foi testado diante de uma única Combinação de Estilos de Aprendizagem, chamada de Estilos de Aprendizagem Probabilísticos (EAs Probabilísticos). Esse processo teve início com a definição do Modelo do Estudante, que em todos os experimentos teve as probabilidades definidas conforme a Tabela 7 (ver p. 90). Os EAs Probabilísticos consistem nos EAs com a maior probabilidade de ocorrência presentes no ME: $EA_{Prob} = \{Ati, Sen, Vis, Seq\}$.

Em seguida, foram selecionados 50 conceitos a serem apresentados ao estudante, sendo que cada conceito somente foi aprendido caso o estudante atingisse todos os níveis de conhecimento definidos na Taxonomia de Bloom. Como ao todo são 6 níveis de conhecimento, a quantidade mínima de sessões de aprendizagem para cada parâmetro de entrada do sistema (EAs reais do estudante) é 300, resultado da multiplicação entre a quantidade de níveis da taxonomia e a quantidade de conceitos a serem vistos.

4.2.2 Realização dos experimentos

O algoritmo foi executado 30 vezes para cada um dos 16 possíveis perfis reais, representados pelas 16 Combinações dos Estilos de Aprendizagem (2^4), o que permitiu a observação do comportamento da ferramenta ao longo de diferentes situações. Cada perfil de estudante teve as dimensões Percepção e Processamento compostas por EAs de peso forte, o EA da dimensão Entrada teve peso moderado e o da dimensão Organização recebeu peso leve.

Franzoni e Assar (2009) entendem que o aluno não possui apenas um EA, mas sim uma combinação deles, pois uma pessoa pode ter preferências por EAs em mais de uma dimensão do Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM). Dessa forma, existem, de acordo com a visão dos autores sobre o FSLSM, 16 tipos de estudantes, de modo que cada um deles tem uma resposta para as seguintes questões:

- que tipo de informação (fatos concretos ou abstrações) ele prefere receber?;
- como ele prefere receber a informação (através de palavras ou imagens)?;

- como essa informação é processada (em grupo ou individualmente)?;
- como se dá a busca pelo conhecimento (por meio de etapas definidas ou não)?

Considerando que as respostas para essas perguntas representam as preferências do estudante no processo de aprendizagem, todo aluno possui um dos 16 perfis existentes.

Para facilitar o processo de análise estatística, ao final das execuções foram contabilizadas as quantidades de sessões de aprendizagem para cada perfil real avaliado. Isso fez-se necessário para que pudessem ser feitas comparações entre os resultados desta proposta e da abordagem apresentada por Dorça (2012).

Os parâmetros para a realização dos testes foram definidos da seguinte maneira:

- Quantidade de conceitos: 50 para ambos os algoritmos;
- Taxa de aprendizagem do agente (α): 0,5 para o método encontrado na literatura e variável para o método aqui proposto;
- Valor mínimo (MMEP) exigido pelo sistema: 60 para o algoritmo aqui proposto;
- Valor mínimo (desempenho) exigido pelo sistema: 60 para o algoritmo proposto em 2012;
- Valor de θ no cálculo da MMEP: 0,1 apenas para o algoritmo com aplicação de MMEP.

Nas seções 5.2.1, 5.2.2 e 5.2.3, são apresentados alguns dos experimentos realizados. Ao todo, foram simuladas as 16 Combinações de Estilos de Aprendizagem, em analogia aos 16 perfis de estudante existentes. Cada perfil foi simulado 30 vezes, dentre as quais os melhores resultados de cada abordagem foram selecionadas para participar dos experimentos.

4.2.3 Análise estatística

A análise estatística dos resultados foi feita utilizando a plataforma estatística R sobre 2 conjuntos de dados, sendo cada conjunto obtido a partir de um dos métodos: proposto por Dorça (2012) e proposto neste trabalho. A escolha da referida plataforma se deu devido ao fato de ser uma plataforma livre e de fácil utilização.

Cada conjunto de dados reúne as quantidades de sessões de aprendizagem que o método do qual foram extraídos os dados levou até que todos os conceitos fossem vistos pelo estudante considerando todos os níveis da Taxonomia de Bloom. Cada conjunto de dados possuía 30×16 itens, em que 30 é a quantidade de vezes que cada um dos 16 perfis foi testado, totalizando 480 itens.

O objetivo de se realizar essa análise estatística foi identificar a proposta que apresentou o melhor desempenho diante do conjunto de parâmetros definido. A principal

informação utilizada nesse processo de identificação é a quantidade de sessões de aprendizagem de cada abordagem para cada simulação, de modo que quanto menos sessões de aprendizagem for necessário até que o objetivo seja atingido, melhor o método.

Assim, o primeiro passo foi a formulação das hipóteses. Assumiu-se como hipótese nula aquela de que a abordagem proposta em 2012 seria capaz de concluir o processo de aprendizagem com uma quantidade menor de sessões. Por outro lado, a hipótese alternativa é de que a hipótese nula não é verdadeira.

Uma vez formuladas as hipóteses nula e alternativa, foi aplicado, sobre ambos os conjuntos de dados, o teste de normalidade de Shapiro-Wilk, cujo resultado apontou que os dois conjuntos de dados não possuem distribuições normais. Essa afirmação limita os testes de hipóteses aos testes não paramétricos, uma vez que não se conhece a distribuição dos dados desses conjuntos. Assim, com o intuito de identificar a abordagem cujos resultados foram os melhores, optou-se por utilizar o teste de hipóteses de Mann-Whitney.

5 RESULTADOS E ANÁLISES

A princípio tentou-se calcular o sinal de reforço utilizando a MMEP dos desempenhos ao invés do último desempenho encontrado, contudo os resultados não foram satisfatórios. Quando o estudante apresenta um problema de aprendizagem, comumente o valor da MMEP dos desempenhos obtidos anteriormente é maior do que o desempenho obtido pelo estudante na presente sessão de aprendizagem. Esse fato pode ser apontado como uma provável justificativa para os resultados não satisfatórios encontrados a partir da utilização da MMEP no cálculo do reforço. Isso porque o alto valor da MMEP faz com que o sinal do reforço seja muito pequeno, refletindo em uma lenta convergência do algoritmo.

Diante dos resultados ruins da primeira tentativa, uma alternativa seria utilizar o algoritmo apresentado por Awheda e Schwartz (2013), que já combinava aprendizagem por reforço e o conceito de MMEP. Nessa abordagem o cálculo do reforço pôde ser feito conforme a proposta de Dorça (2012). Contudo, mesmo com resultados melhores do que os obtidos nos testes anteriores, os resultados não foram tão bons quanto se esperava. A justificativa para os últimos maus resultados, diferente da situação anterior, estava na forma de atualização do ME. Como os ajustes eram feitos considerando a MMEP das probabilidades anteriores, os ajustes foram muito pequenos, culminando em uma maior quantidade de sessões de aprendizagem necessárias para a apresentação de todo o conteúdo.

A partir dos resultados encontrados, optou-se por desenvolver o método conforme apresentado na seção 4.1, utilizando o conceito de MMEP no processo de decisão sobre a aplicação das modificações no ME. As seções seguintes apresentam os resultados desta proposta.

5.1 Escolha do melhor valor para θ

A busca pelo valor de θ se deu de forma sistemática, o que significa que foram testados diversos valores dentro de um intervalo e aquele que apresentou os melhores resultados foi eleito o melhor valor. Como o valor do coeficiente deve ser um valor entre 0 e 1, definiu-se que os valores testados deveriam variar de 0,1 a 0,9 sendo incrementados sempre em 0,1. Dessa forma, foram testados 9 valores para o fator de suavização.

É importante ressaltar que, como parâmetros para os testes, os 16 possíveis perfis de estudante tiveram definidas para as dimensões Percepção e Processamento EAs fortes. Por sua vez, a dimensão Entrada desses perfis tiveram EAs de peso moderado e os EAs da dimensão Organização sempre foram definidos com peso leve. Esses pesos foram definidos dessa forma com base nos experimentos de Dorça (2012), no intuito de realizar

Tabela 7 – Definição das probabilidades no Modelo do Estudante

Estilo de Aprendizagem	Probabilidade
Ativo	0,70
Reflexivo	0,30
Sensitivo	0,70
Intuitivo	0,30
Visual	0,70
Verbal	0,30
Sequencial	0,70
Global	0,30

comparações dos resultados de ambos algoritmos a partir de execuções com parâmetros idênticos.

Diferente da quantidade mínima de sessões de aprendizagem, a quantidade máxima não é definida. Isso porque devido a desempenhos insatisfatórios obtidos pelo aluno, a quantidade de sessões de aprendizagem pode aumentar em relação à quantidade mínima. Portanto, a quantidade máxima de sessões de aprendizagem vai depender da quantidade de desempenhos abaixo do mínimo exigido.

Ao final das execuções foram coletadas as quantidades de sessões de aprendizagem necessárias até que o estudante alcançasse o nível de conhecimento máximo em todos os conceitos selecionados. Assim, para cada perfil de aluno, e para cada fator de suavização aplicado, obtiveram-se 30 valores. Em seguida foi calculada a média geral de sessões de aprendizagem por valor de θ . Isso consistiu em calcular a média das quantidades de sessões de aprendizagem de todos os perfis para cada valor do fator de suavização. O resultado desse cálculo é apresentado na Tabela 8.

Tabela 8 – Média de sessões de aprendizagem por valor de θ

Valor de θ	Média de sessões
0,1	362,04
0,2	362,68
0,3	361,92
0,4	363,26
0,5	364,77
0,6	365,04
0,7	367,37
0,8	378,63
0,9	389,02

Conforme consta na Tabela 8, as menores médias de sessões de aprendizagem foram obtidas quando o fator de suavização teve os valores 0,1, 0,2 e 0,3. A partir de então, os resultados obtidos, quando esses valores de θ foram utilizados, foram comparados aos

resultados fornecidos pelo método encontrado na literatura. Mesmo as 3 médias não sendo estatisticamente diferentes entre si, conforme resultado obtido a partir da aplicação do método de Mann-Whitney, a comparação entre as quantidades de sessões de aprendizagem para cada valor de θ e a quantidade de sessões do método presente na literatura, permitiu identificar que os resultados obtidos quando utilizado $\theta = 0,1$ foram os melhores. Assim, assume-se 0,1 como o melhor valor para θ .

5.2 Resultados dos experimentos

Uma vez definido o melhor para θ , a próxima etapa foi realizar os testes sobre a proposta aqui apresentada e sobre a proposta elaborada por Dorça (2012). Para isso, foram utilizados os mesmos parâmetros da etapa em que houve a escolha do melhor valor para o coeficiente de suavização.

O Modelo do Estudante, assim como os parâmetros já mencionados, foi definido da mesma forma que na definição do valor de θ : EAs Probabilísticos compostos pelos EAs Ativo, Sensitivo, Visual e Sequencial, tendo todos, como probabilidade, 0,70. Lembrando que o processo de aprendizagem é um processo não determinístico e que simulações cujas condições iniciais são idênticas podem não fornecer o mesmo comportamento e, consequentemente, o mesmo resultado.

O intuito de comparar os resultados dos dois algoritmos é verificar e validar a maior eficiência do método aqui proposto em relação ao método proposto por Dorça (2012). Sendo assim, análises estatísticas foram realizadas de maneira a evidenciar as diferenças dos resultados tanto por estratégia pedagógica quanto de um modo geral.

Resumos das médias de sessões de aprendizagem e das médias das notas do estudante são apresentados em duas tabelas. Na Tabela 9 (ver página 92) são comparadas as quantidades médias de sessões de aprendizagem de cada abordagem para cada perfil simulado, bem como seus respectivos desvios-padrão; e na Tabela 10 (ver página 92) são apresentadas as médias das notas obtidas para cada perfil simulado, bem como seus respectivos desvios-padrão. Em ambas as tabelas, o melhor resultado é destacado em negrito de forma a facilitar sua identificação.

Percebe-se, com base nas médias de sessões de aprendizagem presentes na Tabela 9, que, para alguns perfis simulados, ambas as abordagens apresentaram dificuldades para identificar os EAs do aluno. É o caso dos perfis 4, 6, 7, 10, 11 e 13, os quais apresentaram médias acima de 400 sessões. Por outro lado, para os outros perfis, ambas detectaram os EAs com mais facilidade, apresentando médias abaixo de 370 sessões de aprendizagem. Assim, os perfis simulados são divididos em 2 grupos: o grupo daqueles que tiveram seus EAs identificados com maior dificuldade, e o grupo daqueles cujos EAs foram detectados com menor dificuldade.

Diante disso, optou-se por detalhar alguns experimentos de perfis pertencentes a ambos os grupos, como forma de apresentar situações que podem ocorrer durante o

Tabela 9 – Médias de sessões de aprendizagem e seus desvios-padrão

Perfil simulado	Dorça		Ribeiro	
	Média	Desvio-padrão	Média	Desvio-padrão
Perfil 1 = {Ati, Sen, Vis, Seq}	326,36	22,78	319,96	16,79
Perfil 2 = {Ref, Sen, Vis, Seq}	351,5	41,20	325,46	31,51
Perfil 3 = {Ati, Int, Vis, Seq}	343,96	41,81	329,2	36
Perfil 4 = {Ref, Int, Vis, Seq}	433,1	11,32	429,3	16,34
Perfil 5 = {Ati, Sen, Ver, Seq}	345,66	38,32	338,6	32,11
Perfil 6 = {Ref, Sen, Ver, Seq}	428,1	11,39	426,73	15,12
Perfil 7 = {Ati, Int, Ver, Seq}	428,93	17,78	429,86	15,22
Perfil 8 = {Ref, Int, Ver, Seq}	313,5	9,87	316,9	11,03
Perfil 9 = {Ati, Sen, Vis, Glo}	360,93	48,88	329,06	35,82
Perfil 10 = {Ref, Sen, Vis, Glo}	432,2	12,80	431,1	13,51
Perfil 11 = {Ati, Int, Vis, Glo}	429,3	13,10	428,96	13,37
Perfil 12 = {Ref, Int, Vis, Glo}	313	9,95	316,26	15,22
Perfil 13 = {Ati, Sen, Ver, Glo}	428,8	12,92	427,9	15,12
Perfil 14 = {Ref, Sen, Ver, Glo}	316,03	10,10	317,4	13,01
Perfil 15 = {Ati, Int, Ver, Glo}	314,23	10,52	317,43	13,9
Perfil 16 = {Ref, Int, Ver, Glo}	308,33	3,77	308,6	5,82

Tabela 10 – Médias das notas e seus desvios-padrão

Perfil simulado	Dorça		Ribeiro	
	Média	Desvio-padrão	Média	Desvio-padrão
Perfil 1 = {Ati, Sen, Vis, Seq}	84,29	15,94	85,19	14,56
Perfil 2 = {Ref, Sen, Vis, Seq}	74,51	18,03	77,03	15,44
Perfil 3 = {Ati, Int, Vis, Seq}	75,30	17,33	76,69	15,76
Perfil 4 = {Ref, Int, Vis, Seq}	69,85	19,34	69,98	19,49
Perfil 5 = {Ati, Sen, Ver, Seq}	75,25	17,50	75,87	16,77
Perfil 6 = {Ref, Sen, Ver, Seq}	69,83	19,37	70,3	19,37
Perfil 7 = {Ati, Int, Ver, Seq}	69,93	19,44	69,92	19,44
Perfil 8 = {Ref, Int, Ver, Seq}	78,73	13,47	78,11	14,15
Perfil 9 = {Ati, Sen, Vis, Glo}	73,92	18,48	76,74	15,72
Perfil 10 = {Ref, Sen, Vis, Glo}	69,78	19,34	70	19,42
Perfil 11 = {Ati, Int, Vis, Glo}	69,96	19,19	70,08	19,59
Perfil 12 = {Ref, Int, Vis, Glo}	78,56	13,62	78,15	14,26
Perfil 13 = {Ati, Sen, Ver, Glo}	69,97	19,22	70,19	19,51
Perfil 14 = {Ref, Sen, Ver, Glo}	78,23	13,97	78,19	14,22
Perfil 15 = {Ati, Int, Ver, Glo}	78,52	13,77	78,13	14,11
Perfil 16 = {Ref, Int, Ver, Glo}	87,74	10,55	87,58	10,73

processo de aprendizagem e o comportamento do modelo desenvolvido neste trabalho diante dessas situações. Pertencentes ao primeiro grupo, foi selecionado um experimento realizado sobre o perfil 4, enquanto que, pertencentes ao segundo grupo foram escolhidos experimentos sobre os perfis 1 e 8. Como o segundo grupo foi consideravelmente maior do que o primeiro, foram selecionados 2 perfis pertencentes a ele: um perfil cuja média de sessões de aprendizagem foi menor quando comparada com a média do método presente na literatura (Perfil 1), e um perfil que apresentou uma média de sessões de aprendizagem maior em relação ao método de 2012 (Perfil 8).

As seções 5.2.1, 5.2.2 e 5.2.3 têm como objetivo apresentar situações observadas durante o processo de simulação de aprendizagem. Nelas são feitas análises sobre comportamento da abordagem aqui desenvolvida sobre os experimentos dos 3 perfis. Isso porque a discussão dos experimentos sobre todos os perfis não se faz necessária, uma vez que os experimentos não apresentados neste capítulo se assemelham muito àqueles aqui discutidos. Contudo, apesar de não serem aqui discutidos, seus gráficos e tabelas são apresentados no Apêndice A.

5.2.1 Experimento com o Perfil 1

O primeiro experimento foi realizado a partir da simulação de um estudante que possui as seguintes preferências de aprendizagem: Ativo, Sensitivo, Visual e Sequencial. Percebe-se que as preferências desse perfil de estudante coincidem com as preferências definidas inicialmente no ME. Com base nessa informação, espera-se que a quantidade média de sessões de aprendizagem necessárias para que ocorra a detecção dos EAs do estudante seja baixa.

A partir de então verificou-se, ao final das 30 simulações do referido perfil, a quantidade média de sessões de aprendizagem para ambas as abordagens, bem como seus respectivos desvios-padrão. Como resultado, a abordagem presente na literatura, aqui nomeada abordagem 1, obteve uma média de aproximadamente 326,36 sessões de aprendizagem, chamada de média 1. Por outro lado, o método proposto neste trabalho (abordagem 2), considerando as mesmas condições, obteve uma média de, aproximadamente, 319,96 sessões de aprendizagem, chamada média 2.

Apesar de a média 2 ter sido menor do que a média 1, é necessário verificar, também, a dispersão dos dados (números de sessões de aprendizagem) em torno de ambas as médias. Para isso, foi calculado o desvio-padrão das médias de ambas as abordagens. Como resultado, obteve-se, para a abordagem 1, um desvio-padrão de aproximadamente, 22,78. Por outro lado, o resultado do mesmo cálculo, considerando a abordagem 2, obteve um desvio-padrão de, aproximadamente, 16,79. Esses valores mostram que os dados gerados pela abordagem 1, e utilizados no cálculo da média 1, estão mais distantes dessa média quando comparados aos dados fornecidos pela abordagem 2 em relação à média 2. As médias e seus desvios-padrão podem ser observados na Tabela 11 e nos gráficos das

Figuras 13 e 14, na página 94.

Tabela 11 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	326,36	22,78
Ribeiro	319,96	16,79

Figura 13 – Distribuição dos dados em torno da média - Perfil 1 - Abordagem de Dorça





Figura 14 – Distribuição dos dados em torno da média - Perfil 1 - Abordagem de Ribeiro



Em ambos os gráficos é possível observar, de forma visual, a distribuição das quantidades de sessões de aprendizagem, ao longo das 30 simulações, em torno das médias

encontradas, representadas graficamente por meio das retas horizontais.

Como forma de verificar se o método aqui proposto, de fato, é capaz de aprimorar o processo de aprendizagem do estudante, foram calculadas as médias das notas dos estudantes em cada abordagem. A nota média obtida a partir de simulações aqui realizadas, utilizando o PESDE, para o método presente na literatura, foi de, aproximadamente, 84,29 pontos em uma escala de 0 a 100 e desvio-padrão 15,94. Por outro lado, as simulações do método proposto neste trabalho geraram uma média de, aproximadamente, 85,19 pontos, também em uma escala de 0 a 100. Como desvio padrão, foi obtido o valor aproximado de 14,56.

Com base nesses dados, percebe-se que, utilizando o método no qual é aplicado o conceito de MMEP, o desempenho médio do estudante, para o perfil simulado, é melhor quando comparado com o desempenho médio do estudante a partir da utilização do método de Dorça (2012). Além disso, o método aqui proposto tem uma distribuição das frequências das notas mais próxima da média em comparação com o método de 2012, o que pode ser comprovado pelos valores de desvio padrão calculado para cada abordagem. A Tabela 12 apresenta as notas médias do estudante de perfil 1 e seus respectivos desvios-padrão.

Tabela 12 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	84,29	15,94
Ribeiro	85,19	14,56

Conforme já mencionado, para apresentar o comportamento do modelo desenvolvido neste trabalho, foi selecionado o experimento em que o processo de aprendizagem foi concluído com a menor quantidade de sessões de aprendizagem em cada perfil detalhado. Assim, o primeiro passo foi verificar, dentre as 30 simulações, aquela cuja quantidade total de sessões de aprendizagem foi a menor.

Ao final da análise, chegou-se à conclusão de que a simulação do perfil 1, cujo processo de aprendizagem foi concluído de forma mais rápida, demorou 304 sessões de aprendizagem. Ao todo, nessa simulação, foram identificados 4 problemas de aprendizagem e 4 ajustes no Modelo do Estudante.

Com base nesses valores, percebe-se que o modelo aqui desenvolvido apresentou comportamento bastante semelhante ao modelo desenvolvido por Dorça (2012), em que ambos apresentam quantidades de ajustes iguais às quantidades de problemas de aprendizagem. Esse comportamento pode ser observado a partir dos gráficos das Figuras 15 e 16 (ver página 96). Além disso, nota-se, pela quantidade de sessões de aprendizagem, que esta abordagem pôde identificar os EAs do estudante sem grandes dificuldades, uma vez que o processo foi concluído com uma quantidade de sessões próxima à quantidade

mínima – 300 sessões de aprendizagem, resultado da multiplicação da quantidade de conceitos (50) pela quantidade mínima de vezes que cada conceito é apresentado ao aluno (6).

Figura 15 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 1





Figura 16 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 1



O gráfico da Figura 15 apresenta a distribuição das notas ao longo do processo de aprendizagem, de modo que cada nota representa uma sessão de aprendizagem. O gráfico da Figura 16, por sua vez, apresenta os valores da MMEP ao longo do mesmo processo, em que, de forma semelhante ao gráfico anterior, cada valor de MMEP representa uma sessão de aprendizagem. As retas $y = 60$, em ambos os gráficos, representam o valor mínimo exigido pelo sistema. Assim, nas sessões em que os dois gráficos apresentarem pontos abaixo dessas retas, ajustes no ME foram realizados.

É possível perceber que os valores abaixo da reta $y = 60$, no primeiro gráfico, são bastante semelhantes aos valores inferiores à mesma reta no segundo gráfico. Como foram identificados 4 problemas de aprendizagem e 4 ajustes no ME, nas mesmas sessões

de aprendizagem em que a nota do aluno esteve abaixo da referida reta, a MMEP também esteve. Essa correspondência pode ser observada nos gráficos.

Outro ponto de destaque nesse experimento é o fato de ajustes terem sido aplicados no ME, mesmo quando a estratégia pedagógica adotada foi adequada às preferências do aluno. Isso evidencia a influência dos fatores aleatórios na sua performance.

5.2.2 Experimento com o Perfil 4

Nesse experimento, as diferenças entre as preferências reais do estudante (presentes no perfil simulado) e a estratégia pedagógica inicialmente adotada ocorrem em duas dimensões do FSLSM. O perfil do estudante tem o seguintes EAs: Reflexivo, Intuitivo, Visual e Sequencial; enquanto as preferências presentes no ME são: Ativo, Sensitivo, Visual e Sequencial.

Assim como no experimento anterior, foram calculadas as quantidades médias de sessões de aprendizagem obtidas por ambas as abordagens ao final das 30 simulações, bem como seus desvios-padrão. Para a abordagem presente na literatura, identificou-se uma média de 433,1 sessões de aprendizagem, com um desvio-padrão aproximado de 11,32. Por outro lado, a média de sessões e o desvio-padrão para a abordagem aqui desenvolvida foram respectivamente 429,3 e 16,34. Esses valores podem ser observados na Tabela 13.

Tabela 13 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	433,1	11,32
Ribeiro	429,3	16,34

Esse perfil é representante do grupo dos perfis simulados, cujas abordagens identificaram os EAs com maior dificuldade. Isso pode ser inferido a partir da comparação entre os valores presentes na Tabela 13 e os valores que compõem a Tabela 11 (ver página 94), apresentada no experimento anterior.

As altas médias encontradas no presente experimento indicam a ocorrência de muitos problemas de aprendizagem ao longo do processo, evidenciando a deficiência nas escolhas das estratégias pedagógicas. Como essas estratégias são escolhidas, neste modelo, através das probabilidades presentes no Modelo do Estudante, infere-se que, devido ao fato de a performance do aluno não ter sido boa, as estratégias pedagógicas e, conseqüentemente, os EAs Probabilísticos não coincidem com os EAs reais do estudante. Isso fez com que a quantidade final de sessões de aprendizagem aumentasse.

As distribuições das quantidades de sessões, ao longo das 30 simulações do presente perfil, para ambos os métodos, podem ser observadas nos gráficos das Figuras 17 e 18, na página 98.

Figura 17 – Distribuição dos dados em torno da média - Perfil 4 - Abordagem de Dorça





Figura 18 – Distribuição dos dados em torno da média - Perfil 4 - Abordagem de Ribeiro



Nesses gráficos, assim como nos gráficos das Figuras 13 e 14 (ver página 94), apresentados no experimento detalhado na seção 5.2.1, são apresentadas as quantidades de sessões de aprendizagem de cada abordagem em torno de uma média, representada em ambos os gráficos por retas horizontais. No primeiro gráfico, a média é representada pela reta $y = 433,1$, enquanto que no segundo, a reta $y = 429,1$ é que representa a média. Além disso, a dispersão dos pontos ao redor de suas médias é representada, respectivamente, pelos desvios-padrão 11,32 e 16,34, o que indica que os pontos do primeiro gráfico encontram-se mais próximos de sua média, quando comparados com os pontos e com a média do segundo.

Além das médias de sessões, foram calculadas as médias das notas do aluno em ambas as abordagens. Essas médias, juntamente com seus desvios-padrão, são apresentadas na Tabela 14 (ver página 99).

Tabela 14 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,85	19,34
Ribeiro	69,98	19,49

De acordo com os dados da Tabela 14, nota-se, para o perfil 4, grande semelhança entre os desempenhos dos dois métodos, nos quais o aluno obteve notas médias muito próximas, com uma leve superioridade quando utilizado o método aqui apresentado – 69,85 do método desenvolvido em 2012 e 69,98 do método aqui elaborado. Por outro lado, o desvio-padrão dos dados fornecidos por esta abordagem, apesar de muito próximo, também foi superior ao desvio-padrão dos dados oriundos do método proposto por Dorça (2012) – 19,34 para o método mais antigo e 19,49 para o método desenvolvido neste trabalho.

As baixas médias de notas em relação àquelas identificadas no experimento da seção 5.2.1 reforçam a dificuldade encontrada pelos dois métodos para identificar os EAs do aluno. Com base nas médias pode-se inferir que em boa parte das sessões de aprendizagem estratégias pedagógicas inadequadas foram utilizadas, o que, de um modo geral, fez com que o desempenho do aluno fosse baixo.

Para detalhar o funcionamento do método de detecção que utiliza o conceito de MMEP, foi selecionada uma das 30 simulações realizadas sobre o perfil de estudante 4. A escolha da simulação se deu com base na quantidade de sessões necessárias até que o processo de aprendizagem fosse concluído, de modo que a escolhida foi aquela que apresentou a menor quantidade de sessões. Assim, foi selecionada a simulação cuja quantidade de sessões foi igual a 393.

Essa simulação apresentou 93 problemas de aprendizagem, porém foram feitos apenas 86 ajustes no ME. Essa diferença entre a quantidade de problemas e a quantidade de ajustes representa a quantidade de ajustes, considerados desnecessários, evitados pelo sistema. Isso acontece quando há uma queda no desempenho do estudante a ponto de deixá-lo abaixo de 60, performance mínima exigida pelo sistema, porém muito próximo desse valor. O fato de serem muito próximas do valor mínimo exigido pelo sistema, faz com que a queda da MMEP dos desempenhos não seja grande o suficiente para estar abaixo de 60. Assim, estando a nota abaixo de 60 e a MMEP acima desse valor, o conceito é novamente apresentado ao estudante, porém nenhuma alteração é feita no ME.

Os gráficos das Figuras 19 e 20, disponíveis na página 100, mostram, respectivamente, as distribuições das notas e dos valores de MMEP calculados ao longo do

processo de aprendizagem. Cada um dos pontos em ambos os gráficos representam uma sessão de aprendizagem, uma vez que ao final de cada sessão tem-se uma nota como resultado de uma avaliação.

Figura 19 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 4





Figura 20 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 4



As retas $y = 60$ nos dois gráficos representam o desempenho mínimo exigido pelo sistema, o qual é utilizado como parâmetro para que o Componente de Modelagem do Estudante identifique os momentos em que ajustes devem ser feitos no ME.

A quantidade de pontos presentes em ambos os gráficos dificulta a visualização do comportamento do modelo nesse experimento. Contudo, é possível observar que nas últimas sessões de aprendizagem, do lado direito do primeiro gráfico, existem 3 notas abaixo 60, porém muito próximas. Ao se observar o segundo gráfico, percebe-se que apenas 2 desses pontos se mantiveram abaixo da reta $y = 60$. Isso porque a MMEP da sessão de aprendizagem em que o ponto, dentre os 3, que esteve mais próximo da reta foi superior a 60.

Para melhor ilustrar o ocorrido, a Tabela 15 apresenta as notas e os valores de MMEP das últimas 10 sessões de aprendizagem desse experimento (ver página 101).

Tabela 15 – Notas e MMEP das últimas 10 sessões de aprendizagem - Perfil 4

Nº da sessão	Nota	MMEP
393	69,67	68,57
392	55,68	58,70
391	92,11	85,87
390	26,01	29,77
389	63,85	63,61
388	61,54	61,45
387	58,42	60,68
386	81,90	80,98
385	70,97	72,63
384	86,61	87,54

Com base nela, é possível perceber que na sessão de aprendizagem de número 387, a nota do estudante foi abaixo de 60, porém ela não foi baixa o suficiente para fazer com que a MMEP também ficasse abaixo desse valor. Dessa forma, o conceito foi novamente apresentado ao aluno, porém nenhum ajuste foi feito no ME. Esse comportamento foi identificado em 7 oportunidades nessa simulação do perfil 4, portanto, 7 ajustes desnecessários foram evitados a partir da aplicação do conceito de MMEP no processo de decisão sobre a aplicação de modificações no ME.

5.2.3 Experimento com o Perfil 8

Nesse experimento, pela primeira vez é simulado um perfil de estudante que difere das características definidas no ME em três dimensões. Na dimensão Processamento, o estudante simulado possui um EA Reflexivo, enquanto no ME o EA definido para essa dimensão foi Ativo. Quanto à dimensão Percepção, no ME o EA definido é Sensitivo e o EA do estudante é Intuitivo. A dimensão Entrada do estudante simulado tem o EA Verbal, enquanto no ME, o EA dessa dimensão é Visual. Por fim, a dimensão Organização apresenta o mesmo EA em ambos, Sequencial no estudante simulado e Sequencial no ME.


O cálculo das médias e desvios-padrão das quantidades de sessões de aprendizagem obtidas por cada abordagem são os parâmetros utilizados no processo de comparação dos desempenhos do método desenvolvido por Dorça (2012) e do método apresentado neste estudo. Esse cálculo forneceu, para o método desenvolvido em 2012, uma média de 313,5 sessões de aprendizagem e um desvio-padrão de 9,87. O mesmo cálculo, aplicado sobre os dados fornecidos por esta abordagem, obteve uma média de 316,9 sessões e um desvio-padrão de 11,03. A Tabela 16 dispõe esses valores de forma organizada.

Tabela 16 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	313,5	9,87
Ribeiro	316,9	11,03

Percebe-se, com base na Tabela 16, que a abordagem presente na literatura, para o perfil de estudante 8, concluiu o processo de aprendizagem com uma média de sessões menor do que a abordagem aqui desenvolvida. Além disso, percebe-se que a distribuição desses dados foi favorável ao método mais antigo, o qual apresentou uma menor dispersão dos dados utilizados no cálculo da média, conforme apontam os desvios-padrão de ambas as médias. Isso significa que as quantidades de sessões de aprendizagem obtidas pelo método proposto por Dorça (2012), no caso do perfil 8, estiveram mais próximas da média de sessões quando comparados com os dados obtidos pelo modelo apresentado neste trabalho. Essas distribuições podem ser observadas nos gráficos das Figuras 21 e 22.


Figura 21 – Distribuição dos dados em torno da média - Perfil 8 - Abordagem de Dorça



Nota-se, no primeiro gráfico, que há uma maior concentração de pontos próximos à reta que indica a média de sessões de aprendizagem obtida a partir da utilização do método proposto por Dorça (2012), $y = 313,5$. Por outro lado, no segundo gráfico, percebe-se uma maior dispersão das quantidades de sessões, as quais encontram-se mais distantes da reta $y = 316,9$, a qual representa a média de sessões do modelo apresentado neste estudo. Essas observações são comprovadas pelos valores dos desvios-padrão dispostos na Tabela 16 (ver página 102).

Assim como nos experimentos anteriores, foram verificados os desempenhos

Figura 22 – Distribuição dos dados em torno da média - Perfil 8 - Abordagem de Ribeiro



médios obtidos pelo aluno, a partir da utilização de cada método. Pelo método de Dorça (2012), o estudante obteve um desempenho médio aproximado de 78,73 e desvio-padrão 13,47. Quando utilizado o método que utiliza o conceito de MMEP, o desempenho médio do estudante foi de, aproximadamente, 78,11, com desvio-padrão de 14,15. As notas médias e seus desvios-padrão podem ser vistos na Tabela 17.

Tabela 17 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	78,73	13,47
Ribeiro	78,11	14,15

Conforme esperado, as notas médias para ambas as abordagens foram bastante semelhantes, porém, ao contrário do que se percebe no experimento da seção 5.2.2, há uma pequena diferença a favor do método presente na literatura. Nele, nota média do estudante foi superior à nota média obtida pelo aluno quando utilizada a abordagem aqui apresentada. Além disso, a dispersão de suas notas foi menor quando comparada à dispersão das notas pertencentes ao conjunto fornecido por esta abordagem.

Mais uma vez, para observar o comportamento do modelo aqui proposto, foi selecionada a simulação do perfil 8 que obteve a menor quantidade de sessões de aprendizagem. Dessa forma, a simulação escolhida promoveu apenas 4 ajustes e levou 304 sessões até concluir o processo, o que significa que foram identificados, também, 4 problemas de aprendizagem.

A partir dos gráficos das Figuras 23 e 24, na página 104, é possível ver, respectivamente, as notas obtidas pelo aluno e a MMEP dessas notas ao longo de todo o

processo.

Figura 23 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 8





Figura 24 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 8



Ao contrário do que foi observado nos gráficos das Figuras 19 e 20 (ver página 100), em que a quantidade de notas inferiores a 60 é maior do que a quantidade de vezes em que a MMEP das notas foi inferior a esse valor, no presente experimento a MMEP esteve abaixo de 60 uma vez a mais do que as notas. Nota-se, no primeiro gráfico, que 4 pontos abaixo da reta que representa o desempenho mínimo exigido pelo sistema. No segundo gráfico, porém, existem 5 pontos abaixo da reta $y = 60$. Isso aconteceu porque foram identificados, em seguida, um desempenho muito baixo e um desempenho alto, porém esse último não foi alto o bastante para fazer com que o valor da MMEP fosse igual ou superior a 60.

Nesse caso, nem o conceito foi apresentado novamente ao aluno, nem ajustes foram feitos no ME. A justificativa para isso é que, os ajustes somente são aplicados quando ambas, nota e MMEP, são inferiores a 60, e o conceito é repetido pelo estudante

quando a nota é inferior ao mínimo exigido pelo sistema. Dessa forma, foram aplicados 4 ajustes, mesmo número de problemas de aprendizagem.

5.3 Análise estatística

A primeira análise sobre os conjuntos foi feita para descobrir se os dados provêm de populações de distribuições normais. Para isso, foi utilizado o método de Shapiro-Wilk. Esse método foi escolhido por já estar implementado na plataforma estatística utilizada e por figurar entre os principais testes de normalidade, apresentando uma das maiores precisões dentre esses (TORMAN; COSTER; RIBOLDI, 2012).

Sabendo que a hipótese nula assumida nos teste foi de que ambos os conjuntos de dados são oriundos de populações de distribuições normais, o teste foi realizado com o intuito de aceitar ou rejeitar tal hipótese. Assim, ao final dos testes pôde-se concluir que, em um nível de significância de 0,05, a hipótese nula pode ser rejeitada. Assim, os conjuntos de dados não apresentam distribuições normais.

O fato de saber que os conjuntos não apresentam distribuições normais não significa que as distribuições são conhecidas, mas sim que não se tem conhecimento sobre as distribuições das amostras. Para esse tipo de situação são utilizados os testes de hipóteses não paramétricos. Apesar de serem menos eficientes do que os testes paramétricos, eles podem representar o único recurso para a realização da análise estatística (LARSON; FARBER, 2010, p.486).

Considerando o fato de ser necessária a aplicação de testes não paramétricos, optou-se por utilizar o teste de Mann-Whitney. Além de, assim como o teste de Shapiro-Wilk, já estar implementado na plataforma utilizada, o teste de Mann-Whitney foi escolhido por ser capaz de tratar conjuntos de dados independentes, de modo que os dados de um conjunto não afetam os dados do outro (LARSON; FARBER, 2010, p.352).

A segunda análise consistiu na aplicação do referido teste de hipóteses sobre ambos conjuntos de dados. Nessa análise, assumiu-se como hipótese nula a hipótese de que a quantidade de sessões de aprendizagem presentes no conjunto de dados gerado pelo algoritmo proposto por Dorça (2012) é menor do que a quantidade de sessões de aprendizagem presentes no outro conjunto, gerado pelo método com aplicação de MMEP.

Ao final do teste, pôde-se concluir, com um nível de confiança de 0,95, que a proposta de Dorça (2012) necessita de uma quantidade maior ou igual à quantidade de sessões de aprendizagem que necessita a abordagem proposta neste trabalho. Isso se deu por meio da rejeição da hipótese nula com base no valor de probabilidade ($p\text{-valor} = 0,04861$), que, apesar de muito próximo do nível de significância, ainda é menor do que ele, reforçando os resultados encontrados a partir dos experimentos.

6 CONCLUSÕES E TRABALHOS FUTUROS

A qualidade do processo de aprendizagem é dependente da soma de uma série de fatores, desde o estado emocional do estudante, até suas preferências dentro do processo, passando ainda pelas estratégias pedagógicas adotadas pelos educadores. Muitos desses fatores são tidos como incertos, pois não se pode precisar ou medir a influência de cada um deles no processo de aprendizagem, nem quando eles podem prejudicar ou favorecer a construção de conhecimentos.

Contudo, outros desses fatores, quando devidamente conhecidos, podem elevar a probabilidade de sucesso do estudante no processo. É o caso dos Estilos de Aprendizagem (EAs), que representam a forma como indivíduos preferem receber e processar a informação (FELDER; SILVERMAN, 1988). A palavra probabilidade é utilizada porque, embora se conheçam alguns desses fatores, os demais ainda exercem influência sobre a aprendizagem.

Na intenção de identificar automaticamente os EAs do estudante enquanto esse utiliza ambientes educacionais em cursos da modalidade de ensino a distância, diversos trabalhos têm sido propostos. Dorça (2012), por exemplo, propõe um método baseado em Aprendizagem por Reforço (AR) e Cadeias de Markov para realizar a modelagem do estudante inferindo os Estilos de Aprendizagem de acordo com o formato atual do Modelo de Estilos de Aprendizagem de Felder e Silverman, apresentado por Felder e Henriques (1995).

Só no ano de 2016, vários trabalhos foram apresentados no mesmo sentido. Em Gonçalves et al. (2016), melhorias sobre as propostas de Dorça et al. (2011), Dorça (2012), Dorça et al. (2012b), Dorça et al. (2012a) são apresentadas, de modo que a modelagem do estudante é feita tanto quando o estudante apresenta desempenhos tidos como insatisfatórios (abaixo de 60, em uma escala de 0 a 100) quanto quando apresenta desempenhos de excelência (estabelecidos conforme indicação pedagógica, tais como 90 e 95). Rodrigues et al. (2016), por sua vez, propõem uma forma diferente de selecionar as estratégias pedagógicas mais apropriadas às preferências do estudante, utilizando, em vez de Cadeias de Markov, Lógica *Fuzzy*.

Essa recorrente busca pelo melhor método de identificação dos EAs do aluno confirma a importância do tratamento personalizado no processo de aprendizagem. Dessa mesma forma, buscando apresentar uma nova proposta de detecção de EAs, este trabalho foi proposto a partir da combinação de Aprendizagem por Reforço, Média Móvel Exponencialmente Ponderada (MMEP) e Estilos de Aprendizagem, precisamente aqueles propostos por Felder e Henriques (1995) através do FSLSM.

Além disso, há de se levar em consideração que em diversos trabalhos, os

autores¹ consideram que o estudante não possui um EA, mas sim uma combinação deles (CEA), de modo que essa CEA possui 4 EAs, sendo um de cada dimensão do FSLSM.

Neste trabalho é realizada a modelagem do estudante, de modo que sempre que o resultado da MMEP dos desempenhos obtidos pelo estudante e a nota do estudante ao final da sessão de aprendizagem forem inferiores ao mínimo exigido pelo sistema (60), o Componente de Modelagem do Estudante altera as probabilidades das preferências, ou Estilos de Aprendizagem Probabilísticos, presentes no Modelo do Estudante. Dessa forma, consideram-se não apenas os resultados obtidos na última sessão de aprendizagem, mas também os resultados obtidos anteriormente quando determinada estratégia pedagógica foi adotada.

Além disso, a taxa de aprendizagem do agente, definida no momento da atualização dos EAs Probabilísticos, é calculada em função do desempenho do estudante, diferente do que foi definido por Dorça (2012), que utiliza sempre o valor 0,5.

O fato de esta proposta levar em consideração os resultados obtidos anteriormente e a performance do estudante ao final da sessão de aprendizagem pode garantir uma detecção mais rápida dos EAs do aluno. Isso porque ela tem a capacidade de garantir uma tendência em situações em que mudanças repentinas e abruptas podem ocorrer. É o caso das situações em que elementos externos ao processo de aprendizagem (humor do aluno, ambiente onde ele tem acesso ao conteúdo, dentre outros) podem influenciar negativamente o seu desempenho, mesmo quando são adotadas as estratégias pedagógicas que coincidem com as preferências do aluno.

Um ponto de grande importância, tido como uma vantagem da proposta aqui apresentada, é a utilização de Aprendizagem por Reforço no processo de modelagem do estudante. Por se tratar de uma tarefa complexa devido às incertezas presentes no processo de aprendizagem, a lista de técnicas de Inteligência Artificial é reduzida consideravelmente. Isso se deve ao fato de muitas das técnicas não serem capazes de tratar incertezas, tornando o cenário propício para aquelas que apresentam tal capacidade, como é o caso do Aprendizagem por Reforço.

Conforme proposto inicialmente e observado nos resultados apresentados anteriormente, a combinação de AR, MMEP e FSLSM mostrou-se capaz de agilizar o processo de detecção dos EAs de estudantes a partir da eliminação dos ajustes desnecessários no ME, para a maioria dos perfis simulados. Devido à precisão no processo de modelagem, a quantidade de sessões de aprendizagem necessárias até que todo o processo de simulação fosse concluído fosse menor quando comparada à quantidade de sessões de aprendizagem obtidas a partir da simulação do método proposto por Dorça (2012), considerando as mesmas condições iniciais.

Essa diferença entre as quantidades de sessões de aprendizagem obtidas a partir

¹ Franzoni et al. (2008), Franzoni e Assar (2009), Dorça et al. (2012b), Dorça et al. (2012a), Dorça et al. (2013a), Dorça et al. (2013b), Gonçalves et al. (2016), Rodrigues et al. (2016), Sena et al. (2016)

da simulação de ambos os métodos foi apurada estatisticamente através do método não-paramétrico de Mann-Whitney. Como resultado da análise estatística, pode-se afirmar, a um nível de confiança de 0,95 e com base no valor de probabilidade (0,04861), que se pode descartar a hipótese nula de que a quantidade de sessões de aprendizagem obtidas a partir da simulação do método de Dorça (2012) é menor do que a quantidade de sessões de aprendizagem obtidas a partir da simulação do método proposto neste trabalho.

Além dos resultados estatísticos apresentados, é possível verificar, a partir dos gráficos apresentados nos experimentos, que a utilização do conceito de MMEP no processo de decisão sobre a aplicação de reforços nas probabilidades do ME, e as políticas de ajustes dos EAs Probabilísticos baseadas na variação da taxa de aprendizagem do agente em função da performance do estudante, permitem agilizar o processo de modelagem do estudante e detecção dos seus EAs, na maioria dos perfis, conforme apresentado na Tabela 9 (ver página 92). Nela, é possível perceber que os perfis 1, 2, 3, 4, 5, 6, 9, 10, 11 e 13 apresentaram menores médias de sessões de aprendizagem em relação às médias obtidas pelo método de Dorça (2012).

A contribuição desta proposta, bem como seu sucesso, é mais evidente quando analisados os experimentos em que a quantidade de sessões de aprendizagem foram maiores. Neles, a quantidade de problemas de aprendizagem difere da quantidade de ajustes no ME. Com base nas simulações de ambos os métodos, percebe-se que na simulação do método apresentado por Dorça (2012), sinais de reforços são aplicados no ME um maior número de vezes quando comparado com a quantidade de modificações realizadas pela abordagem apresentada neste estudo.

Outra vantagem proporcionada pela presente abordagem é a redução do índice de evasão, preocupação destacada por Laguardia (2009) e que tem como alguns dos motivos o fracasso no curso e estratégias pedagógicas que não coincidem com as formas através das quais o estudante prefere aprender. A utilização da MMEP juntamente com AR agiliza o processo de detecção dos EAs do estudante, consequentemente, a escolha das melhores formas de se apresentar o conteúdo ao aluno é feita com mais precisão. Assim, com estratégias pedagógicas que casam com as preferências e estilos de aprendizagem do estudante, sua aprendizagem é facilitada e seu sucesso é iminente. Isso faz com que o índice de desistências por motivos pedagógicos e de fracasso no curso seja cada vez menor.

O fato de ser um método de identificação dinâmico, pois a modelagem do estudante é feita ao longo do processo de aprendizagem, faz com que a precisão desta proposta seja ponto de destaque diante de outros métodos encontrados na literatura. Conforme apresentado por Hwang et al. (2013), processos de detecção manuais baseados em questionários são caracterizados como imprecisos, uma vez que a identificação ocorre apenas no início da aprendizagem. Assim, se as preferências do estudante sofrerem alterações durante o processo, a seleção dos métodos de apresentação do conteúdo serão prejudicados e, consequentemente, todo o processo logo o será.

Por se tratar de elemento chave para a velocidade da reação, estimar o melhor valor possível para θ é ponto crucial para o aumento da velocidade no processo de identificação de EAs. Como a escolha do melhor valor, neste trabalho, foi feita de forma sistemática, testando cada valor entre 0,1 e 0,9, propõe-se, a título de melhorias futuras, a elaboração de um método capaz de estimar, ao longo da execução do algoritmo, o melhor valor para θ a cada sessão de aprendizagem. Estimando-se um valor ótimo, garante-se o melhor desempenho do algoritmo em qualquer situação, proporcionando uma identificação mais rápida dos EAs.

Conforme presente na literatura, há outras formas de se fazer a seleção das estratégias pedagógicas. Diante disso, melhores resultados podem ser obtidos a partir da combinação de uma boa modelagem do estudante com diferentes métodos de seleção de CEAs. Uma possível contribuição seria a substituição das Cadeias de Markov para a seleção das CEAs pelo uso da Lógica *Fuzzy* conforme propõem Rodrigues et al. (2016).

Todo o processo de verificação e validação foi feito por meio de simulação computacional. Assim, um próximo passo seria aplicar o modelo proposto em ambientes reais de aprendizagem. Isso permitiria a extração de novos dados, os quais, quando manipulados, forneceriam informações mais aprofundadas, tanto sobre o processo de aprendizagem, quanto sobre a performance do método aplicado.

Outra proposta seria a aplicação do modelo aqui apresentado juntamente com sistemas capazes de fazer a recomendação de objetos de aprendizagem. Assim, este modelo seria responsável por fazer as inferências sobre as preferências do aluno ao longo do processo, enquanto objetos de aprendizagem seriam recomendados ao estudante com base nessas inferências.

REFERÊNCIAS

- AHMAD, N.; TASIR, Z. Threshold value in automatic learning style detection. *Procedia - Social and Behavioral Sciences*, Elsevier B.V., v. 97, p. 346–352, 2013. ISSN 18770428. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042813036896>. Acesso em: 05/08/2017.
- AHMAD, N. et al. Automatic Detection of Learning Styles in Learning Management Systems by Using Literature-Based Method. *Procedia - Social and Behavioral Sciences*, v. 103, p. 181–189, 2013. ISSN 18770428. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042813037695>. Acesso em: 05/08/2017.
- ANDRIUS, B. A. et al. Approach of implementation of an intelligent enterprise staff adaptive E-learning. In: *IFAC Proceedings Volumes (IFAC-PapersOnline)*. [S.l.]: Elsevier B.V., 2006. v. 9, n. PART 1, p. 321–326. ISBN 9783902661050. ISSN 14746670.
- AWHEDA, M. D.; SCHWARTZ, H. M. Exponential Moving Average Q-Learning Algorithm. *IEEE Symposium on Adaptive Dynamic Programming and Reinforcement Learning, ADPRL*, p. 31–38, 2013. ISSN 23251824. Disponível em: <http://ieeexplore.ieee.org/document/6614986/>. Acesso em: 05/08/2017.
- BLOOM, B. S. et al. *Taxonomy of Educational Objectives: The Classification of Educational Goals*. [S.l.]: David McKay Company Inc., 1956. 207 p.
- BOX, G. E. P.; HUNTER, J. S.; HUNTER, W. G. *Statistics for Experimenters: Design, Innovation and Discovery*. 2nd ed.. ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2005. 655 p. ISBN ISBN 0-471-71813-0.
- BRAGHETTO, K. R. *Técnicas de modelagem para a análise de desempenho de processos de negócio*. 151 p. Tese (Doutorado) — Universidade de São Paulo, 2011. Disponível em: <http://www.teses.usp.br/teses/disponiveis/45/45134/tde-17112011-160718/>. Acesso em: 05/08/2017.
- BROWN, J. S.; BURTON, R. R.; BELL, A. G. Sophie: a Step Toward Creating a Reactive Learning Environment. *International Journal of Man-Machine Studies*, v. 7, n. 5, p. 675–696, 1975. ISSN 00207373 (ISSN). Disponível em: <http://www.scopus.com/inward/record.url?eid=2-s2.0-0016545659&partnerID=40&md5=834df5ae69cbcbf4e7b3674a7b56f547>. Acesso em: 05/08/2017.
- BRUSILOVSKY, P. Methods and Techniques of Adaptive Hypermedia. *User Modeling and User-Adapted Interaction: The Journal of Personalization Research*, v. 6, n. 2-3, p. 87–129, 1996. ISSN 0924-1868. Disponível em: <https://link.springer.com/article/10.1007/BF00143964>. Acesso em: 05/08/2017.
- BRUSILOVSKY, P. Adaptive Hypermedia: From Intelligent Tutoring Systems to Web-Based Education. *Intelligent Tutoring Systems*, v. 1839, p. 1–7, 2000. Disponível em: <http://www.pitt.edu/~peterb/papers/ITS00inv.html>. Acesso em: 05/08/2017.

- BRUSILOVSKY, P. Adaptive Hypermedia. *User Modeling and User-Adapted Interaction*, v. 11, n. 1-2, p. 87–110, 2001. ISSN 09241868. Disponível em: <http://www.umuai.org/anniversary/brusilovsky-umuai-2001.pdf>. Acesso em: 05/08/2017.
- BRUSILOVSKY, P. Adaptive educational hypermedia: From generation to generation. *Proceedings of 4th Hellenic Conference on Information and Communication Technologies in Education Athens Greece*, p. 19–33, 2004. Disponível em: http://www2.sis.pitt.edu/~peterb/papers/PB_ETPE_04.pdf. Acesso em: 05/08/2017.
- BRUSILOVSKY, P.; MILLÁN, E. User Models for Adaptive Hypermedia and Adaptive Educational Systems. *The Adaptive Web*, p. 3–53, 2007. ISSN 10980121. Disponível em: https://link.springer.com/chapter/10.1007%2F978-3-540-72079-9_1. Acesso em: 05/08/2017.
- BURGOS, T. d. L. *Comunicação gráfica em interfaces de hipermídia de educação a distância via web*. 229 p. Tese (Doutorado) — Universidade Federal do Rio Grande do Norte, Natal, 2010.
- CARBONELL, J. R. AI in CAI: An Artificial-Intelligence Approach to Computer-Assisted Instruction. *Ieee Transactions on Man-Machine Systems*, v. 11, n. 4, p. 190 – 202, 1970. ISSN 0536-1540. Disponível em: <http://ieeexplore.ieee.org/document/4081977/>. Acesso em: 05/08/2017.
- CASSIDY, S. Learning Styles: An overview of theories, models, and measures. *Educational Psychology*, v. 24, n. 4, p. 419–444, 2004. ISSN 0144-3410. Disponível em: http://www.acdowd-designs.com/sfsu_860.11/LS_OverView.pdf. Acesso em: 05/08/2017.
- CAVUS, N. Distance Learning and Learning Management Systems. *Procedia - Social and Behavioral Sciences*, Elsevier B.V., v. 191, p. 872–877, 2015. ISSN 18770428. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042815028712>. Acesso em: 05/08/2017.
- CAVUS, N.; ALHIH, M. S. Learning management systems use in science education. *Procedia - Social and Behavioral Sciences*, Elsevier B.V., v. 143, p. 517–520, 2014. ISSN 18770428. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042814043572>. Acesso em: 05/08/2017.
- CAVUS, N.; ZABADI, T. A Comparison Of Open Source Learning Management Systems. *Procedia - Social and Behavioral Sciences*, Elsevier B.V., v. 143, p. 521–526, 2014. ISSN 18770428. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1877042814043584>. Acesso em: 05/08/2017.
- COFFIELD, F. et al. *Learning styles and pedagogy in post-16 learning A systematic and critical review*. [S.l.], 2004. 182 p. Disponível em: <http://www.leerbeleving.nl/wp-content/uploads/2011/09/learning-styles.pdf>. Acesso em: 05/08/2017.
- DASCALU, M.-I. et al. A recommender agent based on learning styles for better virtual collaborative learning experiences. *Computers in Human Behavior*, Elsevier Ltd, v. 45, n. 0, p. 243–253, 2015. ISSN 07475632. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0747563214007432>. Acesso em: 05/08/2017.

//ac.els-cdn.com/S0747563214007432/1-s2.0-S0747563214007432-main.pdf?{_}tid=5cdcf79e-cf89-11e4-8a96-00000aacb360{\&}acdnat=1426915140{_}017bf8671f180e14014d).

DORÇA, F. A. *Uma Abordagem Estocástica Baseada em Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem de Estudantes em Sistemas Adaptativos e Inteligentes para Educação a Distância*. 207 p. Tese (Doutorado) — Universidade Federal de Uberlândia, 2012. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/14314/1/t.pdf>. Acesso em: 05/08/2017.

DORÇA, F. A. et al. Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. *Revista de Informática Teórica e Aplicada*, v. 18, p. 178–204, 2011. Disponível em: http://seer.ufrgs.br/index.php/rita/article/view/rita_v18_n2_p178/12809. Acesso em: 05/08/2017.

DORÇA, F. A. et al. Avaliação de Políticas de Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem : Uma Análise Experimental. In: *23º Simpósio Brasileiro de Informática na Educação (SBIE 2012)*. Rio de Janeiro: Sociedade Brasileira de Computação - SBC, 2012. p. 26–30. ISSN 2316-6533. Disponível em: <http://www.br-ie.org/pub/index.php/sbie/article/view/1700/1461>. Acesso em: 05/08/2017.

DORÇA, F. A. et al. Consistent Evolution of Student Models by Automatic Detection of Learning Styles. *IEEE Latin America Transactions*, v. 10, n. 5, p. 2150–2161, 2012. ISSN 15480992. Disponível em: <http://ieeexplore.ieee.org/document/6362360/>. Acesso em: 05/08/2017.

DORÇA, F. A. et al. Automatic student modeling in adaptive educational systems through probabilistic learning style combinations: a qualitative comparison between two innovative stochastic approaches. *Journal of the Brazilian Computer Society*, v. 19, n. 1, p. 43–58, 2013. ISSN 01046500. Disponível em: <https://link.springer.com/article/10.1007/s13173-012-0078-2>. Acesso em: 05/08/2017.

DORÇA, F. A. et al. Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Systems with Applications*, v. 40, n. 6, p. 2092–2101, 2013. ISSN 09574174. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417412011281>. Acesso em: 05/08/2017.

FALCI, S. H. et al. Uma Nova Abordagem para Aplicação de Reforço em Sistemas Automáticos e Adaptativos de Detecção de Estilos de Aprendizagem. *Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação*, v. 1, n. 6, 2017. ISSN 2446-7634. Disponível em: <http://revistas.setrem.com.br/index.php/reabtic/article/view/200>. Acesso em: 05/08/2017.

FEHLMANN, T. M.; KRANICH, E. Exponentially Weighted Moving Average (EWMA) Prediction in the Software Development Process. In: *Proceedings - 2014 Joint Conference of the International Workshop on Software Measurement, IWSM 2014 and the International Conference on Software Process and Product Measurement, Mensura 2014*. Roterdã: IEEE, 2014. p. 263–270. ISBN 9781479941742.

FELDER, R.; SILVERMAN, L. Learning and teaching styles in engineering education. *Engineering education*, v. 78, n. June, p. 674–681, 1988. ISSN 01905848. Disponível em: <http://www4.ncsu.edu/unity/lockers/users/f/felder/public/Papers/LS-1988.pdf>. Acesso em: 05/08/2017.

FELDER, R. M.; HENRIQUES, E. R. Learning and Teaching Styles In Foreign and Second Language Education. *Foreign Language Annals*, v. 28, n. 1, p. 21–31, 1995. Disponível em: <http://www4.ncsu.edu/unity/lockers/users/f/felder/public/Papers/FLAnnals.pdf>. Acesso em: 05/08/2017.

FELDER, R. M.; SPURLIN, J. Applications, Reliability and Validity of the Index of Learning Styles*. *International Journal of Engineering Education*, v. 21, n. 1, p. 103–112, 2005. Disponível em: [http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS_Validation\(IJEE\).pdf](http://www4.ncsu.edu/unity/lockers/users/f/felder/public/ILSdir/ILS_Validation(IJEE).pdf). Acesso em: 05/08/2017.

FELDMAN, J.; MONTESERIN, A.; AMANDI, A. Detecting students' perception style by using games. *Computers and Education*, Elsevier Ltd, v. 71, p. 14–22, 2014. ISSN 03601315. Disponível em: <http://dx.doi.org/10.1016/j.compedu.2013.09.007>. Acesso em: 05/08/2017.

FELDMAN, J.; MONTESERIN, A.; AMANDI, A. Automatic detection of learning styles: state of the art. *Artificial Intelligence Review*, Springer Netherlands, v. 44, n. 2, p. 157–186, 2015. ISSN 02692821. Disponível em: <http://dx.doi.org/10.1007/s10462-014-9422-6>. Acesso em: 05/08/2017.

FERNANDES, A. M. d. R.; BENITTI, F. B. V.; CUNHA, F. d. S. Aplicando o Inventário de Estilos de Aprendizagem de Kolb como Ferramenta de Apoio ao Processo de Ensino Aprendizagem em Cursos de Computação. *XXXIII Congresso da Sociedade Brasileira de Computação*, v. 1, p. 420–425, 2013. Disponível em: <http://www.lbd.dcc.ufmg.br/colecoes/wei/2013/008.pdf>. Acesso em: 05/08/2017.

FERRAZ, A. P. d. C. M.; BELHOT, R. V. Taxonomia de Bloom: revisão teórica e apresentação das adequações do instrumento para definição de objetivos instrucionais. *Revista Gestão & Produção*, v. 17, n. 2, p. 421–431, 2010. Disponível em: <http://www.scielo.br/pdf/gp/v17n2/a15v17n2.pdf>. Acesso em: 05/08/2017.

FRANZONI, A. L.; ASSAR, S. Student Learning Styles Adaptation Method Based on Teaching Strategies and Electronic Media. *Educational Technology & Society*, v. 12, n. 4, p. 15–29, 2009. ISSN 1436-4522. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4561832. Acesso em: 05/08/2017.

FRANZONI, A. L. et al. Student Learning Styles Adaptation Method Based on Teaching Strategies and Electronic Media. In: *Eighth IEEE International Conference on Advanced Learning Technologies*. [s.n.], 2008. p. 778–782. ISBN 9780769531670. ISSN 14364522. Disponível em: <http://ieeexplore.ieee.org/document/4561832/>. Acesso em: 05/08/2017.

FRITSCH, H. *Distance Education*. 2001. 3781–3784 p.

FRY, R.; KOLB, D. Experiential Learning Theory and Learning Experiences in Liberal Arts Education. *New Directions for Experiential Learning*, v. 6, n. 1, p. 79–92, 1979.

- GARCÍA, P. et al. Evaluating Bayesian networks' precision for detecting students' learning styles. *Computers and Education*, v. 49, n. 3, p. 794–808, 2007. ISSN 03601315. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0360131505001788>. Acesso em: 05/08/2017.
- GERHARDT, T. E.; SILVEIRA, D. T. *Métodos de pesquisa*. 1. ed. Porto Alegre: Editora da UFRGS, 2009. 120 p. ISSN 1677-5449. ISBN 9788538600718.
- GHADIRLI, H. M.; RASTGARPOUR, M. A web-based Adaptive and Intelligent Tutor by Expert Systems. *Advances in Computing & Information Technology*, v. 177 AISC, n. VOL. 2, p. 87–95, 2013. ISSN 21945357. Disponível em: https://link.springer.com/chapter/10.1007/978-3-642-31552-7_10. Acesso em: 05/08/2017.
- GONÇALVES, A. V. *Modelagem Automática e Dinâmica de Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância: Estudo Comparativo entre Duas Abordagens*. 121 p. Dissertação (Mestrado) — Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM, 2015. Disponível em: http://acervo.ufvjm.edu.br/jspui/bitstream/1/1154/1/andre_vinicius_goncalves.pdf. Acesso em: 05/08/2017.
- GONÇALVES, A. V. et al. Avanços na modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação: uma análise experimental. In: *XXVII Simpósio Brasileiro de Informática na Educação (SBIE 2016)*. Uberlândia: Sociedade Brasileira de Computação - SBC, 2016. p. 1006–1015. ISSN 2316-6533. Disponível em: <http://www.br-ie.org/pub/index.php/sbie/article/view/6786>. Acesso em: 05/08/2017.
- GRAF, S.; KINSHUK; IVES, C. A Flexible Mechanism for Providing Adaptivity Based on Learning Styles in Learning Management Systems. *2010 10th IEEE International Conference on Advanced Learning Technologies*, p. 30–34, 2010. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5571112>. Acesso em: 05/08/2017.
- GRAF, S.; KINSHUK, P. An Approach for Detecting Learning Styles in Learning Management Systems. In: *Sixth IEEE International Conference on Advanced Learning Technologies (ICALT'06)*. [s.n.], 2006. p. 161–163. ISBN 0-7695-2632-2. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1652395>. Acesso em: 05/08/2017.
- GRAF, S.; LIU, T.-C.; KINSHUK. Interactions Between Students' Learning Styles, Achievement and Behaviour in Mismatched Courses. In: *Proceedings of the International Conference on Cognition and Exploratory Learning in Digital Age*. [S.l.]: IADIS International Conference, 2008. p. 223–230. ISBN 9789728924690.
- GRAF, S.; VIOLA, S. R.; LEO, T. In-Depth Analysis of the Felder-Silverman Learning Style Dimensions. *Journal of Research on Technology in Education*, v. 40, n. 1, p. 79–93, 2007. ISSN 1539-1523. Disponível em: <http://www.tandfonline.com/doi/abs/10.1080/15391523.2007.10782498>. Acesso em: 05/08/2017.
- HWANG, G. J. et al. A learning style perspective to investigate the necessity of developing adaptive learning systems. *Educational Technology and Society*, v. 16, n. 2, p. 188–197, 2013. ISSN 11763647.

- IGLESIAS, A. et al. Learning teaching strategies in an Adaptive and Intelligent Educational System through Reinforcement Learning. *Applied Intelligence*, v. 31, n. 1, p. 89–106, 2009. Disponível em: <https://link.springer.com/article/10.1007/s10489-008-0115-1>. Acesso em: 05/08/2017.
- IGLESIAS, A. et al. Reinforcement learning of pedagogical policies in adaptive and intelligent educational systems. *Knowledge-Based Systems*, v. 22, n. 4, p. 266–270, 2009. ISSN 09507051. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0950705109000173>. Acesso em: 05/08/2017.
- INCONTRI, D. Multimídia na educação. *Comunicação & Educação*, São Paulo, v. 3, n. 7, p. 16–20, 1996. ISSN 0104-6829. Disponível em: <http://200.144.189.42/ojs/index.php/comeduc/article/viewArticle/4308>.
- JOHNSON, R. E. Components, frameworks, patterns (extended abstract). In: *Proceedings of the 1997 symposium on Software reusability - SSR '97*. [s.n.], 1997. v. 22, n. 3, p. 10–17. ISBN 0897919459. Disponível em: <http://portal.acm.org/citation.cfm?doid=258366.258378>. Acesso em: 05/08/2017.
- KARA, N.; SEVIM, N. Adaptive Learning Systems : Beyond Teaching Machines. *Contemporary Educational Technology*, v. 4, n. 2, p. 108–120, 2013. Disponível em: <https://eric.ed.gov/?id=EJ1105533>. Acesso em: 05/08/2017.
- KAVCIC, A. The Role of User Models in Adaptive Hypermedia Systems. *10th Mediterranean Electrotechnical Conference, 2000. MELECON 2000.*, I, p. 119–122, 2000. Disponível em: <http://ieeexplore.ieee.org/document/880382/>. Acesso em: 05/08/2017.
- KELLY, D.; TANGNEY, B. ‘First aid for you’: Getting to know your Learning Style using Machine Learning. In: *Proceedings of Fifth IEEE International Conference on Advanced Learning Technologies*. Kaohsiung, Taiwan: IEEE, 2005. p. 1–3. ISBN 0-7695-2338-2. Disponível em: <http://ieeexplore.ieee.org/document/1508590/>. Acesso em: 05/08/2017.
- KINSHUK; LIU, T. C.; GRAF, S. Coping with mismatched courses: Students’ behaviour and performance in courses mismatched to their learning styles. *Educational Technology Research and Development*, v. 57, n. 6, p. 739–752, 2009. ISSN 10421629. Disponível em: <https://link.springer.com/article/10.1007%2Fs11423-009-9116-y>. Acesso em: 05/08/2017.
- KOBSA, A. User Modeling and User-Adapted Interaction. *Conference Companion on Human Factors in Computing Systems*, p. 415–416, 1994. ISSN 09241868. Disponível em: <http://dl.acm.org/citation.cfm?id=260532>. Acesso em: 05/08/2017.
- KOLB, A. Y.; KOLB, D. A. Learning Styles and Learning Spaces: Enhancing Experiential Learning in Higher Education. *Academy of Management Learning & Education*, v. 4, n. 2, p. 193–212, 2005. ISSN 1537260X. Disponível em: <http://www.jstor.org/stable/40214287>.
- KOLB, D. A. Experiential Learning Theory and The Learning Style Inventory: A Reply to Freedman and Stumpf. *Academy of Management Review*, v. 6, n. 2, p. 289–296, 1981. ISSN 0363-7425. Disponível em: <http://amr.aom.org/cgi/doi/10.5465/AMR.1981.4287844>.

- KRATHWOHL, D. R. A Revision of Bloom's Taxonomy: An Overview. *Theory Into Practice*, v. 41, n. 4, p. 212–218, 2002.
- LAGUARDIA, J. Evasão na educação a distância. *ETD - Educação Temática Digital*, v. 11, n. 1, p. 349–379, 2009.
- LARSON, R.; FARBER, B. *Estatística aplicada*. 4. ed. São Paulo: Pearson Education do Brasil, 2010. 656 p. ISBN 9788576053729.
- LÉVY, P. *As tecnologias da inteligência: O futuro do pensamento na era da informática*. 1. ed. Rio de Janeiro: Editora 34, 1993. 208 p. ISBN 9788585490157.
- LU, S.-L.; TSAI, C.-F.; CHEN, J. H. EWMA control charts for statistical detecting QoS violations. In: *Proceedings - 12th IEEE International Conference on E-Business Engineering, ICEBE 2015*. Pequim: IEEE, 2015. p. 198–202. ISBN 9781467380027.
- MILLWARD, R. et al. Intelligent computer-assisted instruction. *Behavior Research Methods & Instrumentation*, v. 10, n. 2, p. 213–217, 1978.
- MILMAN, N. B. *Distance Education*. Elsevier, 2015. 567–570 p. Disponível em: <http://www.sciencedirect.com/science/article/pii/B9780080970868920014>. Acesso em: 05/08/2017.
- MONTGOMERY, D. C.; RUNGER, G. C. Estatística Aplicada e Probabilidade para Engenheiros. In: . 4. ed. Rio de Janeiro: LTC, 2009. cap. 16-10.2 Gr, p. 514.
- NAJJAR, L. J. Multimedia Information and Learning. In: *Jl. of Educational Multimedia and Hypermedia*. [S.l.: s.n.], 1996. v. 5, n. 2, p. 129–150.
- NETO, J. J. Um Levantamento da Evolução da Adaptatividade e da Tecnologia Adaptativa. *IEEE Latin America Transactions*, v. 5, n. 7, p. 496–505, 2007. ISSN 15480992.
- ÖZPOLAT, E.; AKAR, G. B. Automatic detection of learning styles for an e-learning system. *Computers and Education*, Elsevier Ltd, v. 53, n. 2, p. 355–367, 2009. ISSN 03601315. Disponível em: <http://dx.doi.org/10.1016/j.compedu.2009.02.018>. Acesso em: 05/08/2017.
- PAYETTE, J. *Intelligent Computer-Assisted Instruction in Syntactic Style*. 118 p. Dissertação (Mestrado) — Universidade de Toronto, 1990.
- PEIXOTO, J. Relações entre sujeitos sociais* e objetos técnicos** uma reflexão necessária para investigar os processos educativos mediados por tecnologias. *Revista Brasileira de Educação*, v. 20, n. 61, p. 317–332, 2015. ISSN 1809449X. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-24782015000200317&lng=pt&tlng=pt. Acesso em: 05/08/2017.
- PERICO, D. H.; BIANCHI, R. A. C. Use of Heuristics from Demonstrations to Speed Up Reinforcement Learning. *Anais do XI Simpósio Brasileiro de Automação Inteligente (SBAI 2013)*, n. 1, 2013.
- PHAM, Q. D.; FLOREA, A. M. A Method for Detection of Learning Styles in Learning Management Systems. *UPB Scientific Bulletin, Series C: Electrical Engineering*, v. 75, n. 4, p. 3–12, 2013.

PHOBUN, P.; VICHEANPANYA, J. Adaptive intelligent tutoring systems for e-learning systems. *Procedia - Social and Behavioral Sciences*, v. 2, n. 2, p. 4064–4069, 2010. ISSN 18770428. Disponível em: <http://dx.doi.org/10.1016/j.sbspro.2010.03.641>. Acesso em: 05/08/2017.

POLLARD, D. Stochastic Processes as Random Functions. In: *Convergence Of Stochastic Processes*. Nova Iorque: Springer, 1984. cap. I, p. 215. ISBN 0-387-90990-7.

POPESCU, E. Diagnosing Students' Learning Style in an Educational Hypermedia System. In: *Cognitive and Emotional Processes in Web-based Education: Integrating Human Factors and Personalization*. 1. ed. [S.l.]: IGI Global, 2009. cap. XI, p. 187–208. ISBN 9781605663920.

PREE, W.; SIKORA, H. Design Patterns for Object-Oriented Software Development. In: *ICSE '97: Proceedings of the 19th International Conference on Software Engineering*. Boston, MA USA: ACM, 1997. p. 663–664. ISBN 0897919149. ISSN 0270-5257. Disponível em: <http://dl.acm.org/citation.cfm?id=253810>. Acesso em: 05/08/2017.

RODRIGUES, L. H. S. et al. Uso de Lógica Fuzzy na Seleção de Estratégias de Aprendizagem. In: *XXVII Simpósio Brasileiro de Informática na Educação (SBIE 2016)*. Uberlândia: Sociedade Brasileira de Computação - SBC, 2016. p. 1076–1085. ISSN 2316-6533. Disponível em: <http://www.br-ie.org/pub/index.php/sbie/article/view/6793>. Acesso em: 05/08/2017.

RUSSEL, S.; NORVIG, P. *Inteligência Artificial*. 3. ed. Rio de Janeiro: Campus, 2013. ISBN 978-85-352-3701-6.

RUSSELL, S. J.; NORVIG, P. *Inteligência Artificial*. 2. ed. Rio de Janeiro: [s.n.], 2004. 1021 p.

SENA, E. et al. Proposta de uma Abordagem Computacional para Detecção Automática de Estilos de Aprendizagem Utilizando Modelos Ocultos de Markov e FSLSM. In: *XXVII Simpósio Brasileiro de Informática na Educação (SBIE 2016)*. Uberlândia: Sociedade Brasileira de Computação - SBC, 2016. p. 1126. ISSN 2316-6533. Disponível em: <http://www.br-ie.org/pub/index.php/sbie/article/view/6798>. Acesso em: 05/08/2017.

SILVA, D. H.; DORÇA, F. A. Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância. *Revista Brasileira de Informática na Educação*, v. 22, n. 2, p. 1–15, 2014. ISSN 1414-5685. Disponível em: <http://www.br-ie.org/pub/index.php/rbie/article/view/2374>. Acesso em: 05/08/2017.

SILVA, E. d. B. e. et al. Comparação de Políticas de Divisão de Tráfego em Data Center empregando SDN. In: *XXXV Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. Belém: Sociedade Brasileira de Computação - SBC, 2017. p. 73–86. ISSN 2177-496X. Disponível em: <https://sbrc2017.ufpa.br/wp-content/uploads/2017/05/proceedingsSBRC2017.pdf>.

SILVA, L. L. V. *Estilos e estratégias de aprendizagem de estudantes universitários*. 125 p. Dissertação (Mestrado) — Instituto de Psicologia da Universidade de São Paulo, São Paulo, 2012.

- SILVEIRA, S. R. et al. Aplicação de Técnicas de Hipermídia Adaptativa em Sistemas Tutores Inteligentes. *Colabor@ - A Revista Digital da CVA-RICESU*, v. 7, n. 25, 2011. ISSN 1098-6596. Disponível em: <http://www.pead.ucpel.tche.br/revistas/index.php/colabora/article/view/148>. Acesso em: 05/08/2017.
- SIMONSON, M.; SCHLOSSER, C.; ORELLANA, A. Distance education research: A review of the literature. *Journal of Computing in Higher Education*, v. 23, n. 2-3, p. 124–142, 2011. ISSN 10421726. Disponível em: <https://link.springer.com/article/10.1007%2Fs12528-011-9045-8?LI=true>. Acesso em: 05/08/2017.
- SPAGNOL, R. L. *Modelagem de Redes de Computadores por Métodos Estatísticos*. 85 p. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2011. Disponível em: <http://repositorio.unicamp.br/handle/REPOSIP/267780>. Acesso em: 05/08/2017.
- TAYLOR, H. M.; KARLIN, S. Stochastic Modeling. In: *An Introduction to Stochastic Modeling*. 3. ed. Londres: [s.n.], 1998. cap. I, p. 631. ISBN 978-0-12-684887=-8.
- TORMAN, V. B. L.; COSTER, R.; RIBOLDI, J. Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação. *Clinical & Biomedical Research*, v. 32, n. 2, p. 227–234, 2012. ISSN 2357-9730. Disponível em: <http://seer.ufrgs.br/index.php/hcpa/article/view/29874/19186>. Acesso em: 05/08/2017.
- ZAINA, L. A. M. et al. e-LORS: Uma Abordagem para Recomendação de Objetos de Aprendizagem. *Revista Brasileira de Informática na Educação*, v. 20, n. 1, p. 4–16, 2012. ISSN 1414-5685. Disponível em: <http://www.br-ie.org/pub/index.php/rbie/article/view/1289/1190>. Acesso em: 05/08/2017.

APÊNDICE A – EXPERIMENTOS NÃO APRESENTADOS NO CAPÍTULO 5

Experimento com o Perfil 2

O experimento seguinte foi realizado a partir da simulação de um estudante que possui as seguintes preferências de aprendizagem: Reflexivo, Sensitivo, Visual e Sequencial. Nesse momento a diferença entre o perfil de estudante testado e o perfil definido no ME concentra-se apenas na dimensão Processamento, de modo que o perfil do estudante para essa dimensão é Reflexivo e o EA dessa mesma dimensão, no ME, é Ativo.

Tabela 18 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	351,5	41,20
Ribeiro	325,46	31,51

Figura 25 – Distribuição dos dados em torno da média - Perfil 2 - Abordagem de Dorça




Tabela 19 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	74,51	18,03
Ribeiro	77,03	15,44

Figura 26 – Distribuição dos dados em torno da média - Perfil 2 - Abordagem de Ribeiro





Figura 27 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 2



Experimento com o Perfil 3

Para a realização do terceiro experimento o perfil do estudante foi definido com as seguintes preferências de aprendizagem: Ativo, Intuitivo, Visual e Sequencial. Semelhante ao experimento anterior, este foi realizado com diferença apenas na dimensão percepção: o estudante prefere aprender de forma sensitiva e o perfil definido no ME aponta a preferência para uma aprendizagem de forma intuitiva.

Tabela 20 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	343,96	41,81
Ribeiro	329,2	36,00

Figura 28 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 2




Figura 29 – Distribuição dos dados em torno da média - Perfil 3 - Abordagem de Dorça




Tabela 21 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	75,30	17,33
Ribeiro	76,69	15,76

Experimento com o Perfil 5

O experimento de número 5 testa as preferências do estudante com uma diferença em relação às preferências definidas no ME. Neste experimento o estudante tem o seguinte perfil: Ativo, Sensitivo, Verbal e Sequencial, ao passo que o ME possui continua com os seguintes EAs: Ativo, Sensitivo, Visual e Sequencial. Nota-se que a diferença se

Figura 30 – Distribuição dos dados em torno da média - Perfil 3 - Abordagem de Ribeiro





Figura 31 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 3



dá apenas na dimensão Entrada.

Tabela 22 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	345,66	38,32
Ribeiro	338,6	32,11

Experimento com o Perfil 6

Neste experimento ocorre a simulação do processo de aprendizagem de um estudante cujas preferências são: Reflexivo, Sensitivo, Verbal e Sequencial. Novamente

Figura 32 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 3




Figura 33 – Distribuição dos dados em torno da média - Perfil 5 - Abordagem de Dorça




Tabela 23 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	75,25	17,50
Ribeiro	75,87	16,77

tem-se um perfil de estudante cujas características de aprendizagem diferem das características definidas no ME em duas dimensões: Processamento e Entrada.

Figura 34 – Distribuição dos dados em torno da média - Perfil 5 - Abordagem de Ribeiro




Figura 35 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 5




Tabela 24 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	428,1	11,39
Ribeiro	426,73	15,12

Tabela 25 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,83	19,37
Ribeiro	70,3	19,37

Figura 36 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 5





Figura 37 – Distribuição dos dados em torno da média - Perfil 6 - Abordagem de Dorça



Experimento com o Perfil 7

No 7º experimento ocorreu a simulação do estudante com as seguintes características: Ativo, Intuitivo, Verbal e Sequencial. Por outro lado, assim como em todos os demais experimentos, o ME foi definido com os seguintes EAs: Ativo, Sensitivo, Visual e Sequencial. Diferindo do ME nas dimensões Percepção e Entrada, o perfil de estudante foi simulado em ambas as abordagens. Ao final das 30 simulações, aquela cuja quantidade de sessões de aprendizagem foi a menor em cada algoritmo foi escolhida para passar por testes estatísticos.

Figura 38 – Distribuição dos dados em torno da média - Perfil 6 - Abordagem de Ribeiro




Figura 39 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 6




Tabela 26 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	428,93	17,78
Ribeiro	429,86	15,22

Tabela 27 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,93	19,44
Ribeiro	69,92	19,44

Figura 40 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 6





Figura 41 – Distribuição dos dados em torno da média - Perfil 7 - Abordagem de Dorça



Experimento com o Perfil 9

Mais uma vez está sendo simulado um estudante cujo perfil difere do ME apenas em uma dimensão. Neste experimento apenas a dimensão Organização não coincide entre os EAs do estudante e os EAs do ME. O estudante teve seus EAs definidos da seguinte forma: Ativo, Sensitivo, Visual e Global.

Tabela 28 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	360,93	48,88
Ribeiro	329,06	35,82

Figura 42 – Distribuição dos dados em torno da média - Perfil 7 - Abordagem de Ribeiro




Figura 43 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 7




Tabela 29 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	73,92	18,48
Ribeiro	76,74	15,72

Experimento com o Perfil 10

O experimento de número 10 caracteriza-se por apresentar, novamente, duas diferenças entre os EAs do estudante simulado e os EAs presentes no ME. Neste experimento as preferências do estudante foram definidas como Reflexivo, Sensitivo, Visual e Global.

Figura 44 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 7




Figura 45 – Distribuição dos dados em torno da média - Perfil 9 - Abordagem de Dorça




Tabela 30 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	432,2	12,80
Ribeiro	431,1	13,51

Tabela 31 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,78	19,34
Ribeiro	70	19,42

Figura 46 – Distribuição dos dados em torno da média - Perfil 9 - Abordagem de Ribeiro





Figura 47 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 9



Experimento com o Perfil 11

O experimento seguinte simula um estudante com as seguintes preferências de aprendizagem: Ativo, Intuitivo, Visual e Global. Mais uma vez o perfil do estudante diverge dos EAs definidos no ME em duas dimensões: Percepção e Organização.

Tabela 32 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	429,3	13,10
Ribeiro	428,96	13,37

Figura 48 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 9




Figura 49 – Distribuição dos dados em torno da média - Perfil 10 - Abordagem de Dorça




Tabela 33 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,96	19,19
Ribeiro	70,08	19,59

Experimento com o Perfil 12

Para a realização deste experimento o perfil do estudante foi definido com as seguintes preferências de aprendizagem: Reflexivo, Intuitivo, Visual e Global. Com diferença em uma dimensão a mais do que no experimento anterior, a dimensão Percepção do estudante apresenta o EA Intuitivo, enquanto no ME, o EA correspondente a essa

Figura 50 – Distribuição dos dados em torno da média - Perfil 10 - Abordagem de Ribeiro





Figura 51 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 10



dimensão é o Sensitivo.

Tabela 34 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	313	9,95
Ribeiro	316,26	15,22

Experimento com o Perfil 13

O experimento seguinte foi realizado a partir da simulação de um estudante que possui as seguintes preferências de aprendizagem: Ativo, Sensitivo, Verbal e Global.

Figura 52 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 10




Figura 53 – Distribuição dos dados em torno da média - Perfil 11 - Abordagem de Dorça




Tabela 35 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	78,56	13,62
Ribeiro	78,15	14,26

Como os EAs presentes no ME são sempre os mesmos, nesse experimento a diferença entre o perfil de estudante testado e o perfil definido no ME concentra-se em duas dimensões: Entrada e Organização.

Figura 54 – Distribuição dos dados em torno da média - Perfil 11 - Abordagem de Ribeiro




Figura 55 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 11




Tabela 36 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	428,8	12,92
Ribeiro	427,9	15,12

Tabela 37 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	69,97	19,22
Ribeiro	70,19	19,51

Figura 56 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 11





Figura 57 – Distribuição dos dados em torno da média - Perfil 12 - Abordagem de Dorça



Experimento com o Perfil 14

O experimento de número 14 avalia as preferências do estudante com três diferenças em relação às preferências definidas no ME. Nele o estudante tem o seguinte perfil: Reflexivo, Sensitivo, Verbal e Global, ao passo que o ME possui os mesmos EAs que tinha nos outros experimentos: Ativo, Sensitivo, Visual e Sequencial.

Tabela 38 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	316,03	10,10
Ribeiro	317,4	13,01

Figura 58 – Distribuição dos dados em torno da média - Perfil 12 - Abordagem de Ribeiro




Figura 59 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 12




Tabela 39 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	78,23	13,97
Ribeiro	78,19	14,22

Experimento com o Perfil 15

Neste experimento ocorre a simulação do processo de aprendizagem de um estudante cujas preferências são: Ativo, Intuitivo, Verbal e Global. Novamente tem-se um perfil de estudante cujas características de aprendizagem diferem das características definidas no ME em três dimensões: Percepção, Entrada e Organização.

Figura 60 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 12




Figura 61 – Distribuição dos dados em torno da média - Perfil 13 - Abordagem de Dorça




Tabela 40 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	314,23	10,52
Ribeiro	317,43	13,9

Tabela 41 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	78,52	13,77
Ribeiro	78,13	14,11

Figura 62 – Distribuição dos dados em torno da média - Perfil 13 - Abordagem de Ribeiro





Figura 63 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 13



Experimento com o Perfil 16

O experimento de número 16 caracteriza-se por apresentar um perfil de estudante cujas características de aprendizagem são todas diferentes das características definidas no ME. Enquanto o ME permaneceu definido com os EAs: Ativo, Sensitivo, Visual e Sequencial; o perfil estudante simulado tem seus EAs definidos da seguinte forma: Reflexivo, Intuitivo, Verbal e Global.

Tabela 42 – Quantidades médias de sessões de aprendizagem e seus desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	308,33	3,77
Ribeiro	308,6	5,82

Figura 64 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 13




Figura 65 – Distribuição dos dados em torno da média - Perfil 14 - Abordagem de Dorça




Tabela 43 – Notas médias do estudante e seus respectivos desvios-padrão

Abordagem	Média	Desvio-padrão
Dorça	87,74	10,55
Ribeiro	87,58	10,73

Figura 66 – Distribuição dos dados em torno da média - Perfil 14 - Abordagem de Ribeiro




Figura 67 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 14




Figura 68 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 14




Figura 69 – Distribuição dos dados em torno da média - Perfil 15 - Abordagem de Dorça




Figura 70 – Distribuição dos dados em torno da média - Perfil 15 - Abordagem de Ribeiro




Figura 71 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 15




Figura 72 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 15




Figura 73 – Distribuição dos dados em torno da média - Perfil 16 - Abordagem de Dorça




Figura 74 – Distribuição dos dados em torno da média - Perfil 16 - Abordagem de Ribeiro




Figura 75 – Distribuição das notas ao longo do processo de aprendizagem - Perfil 16




Figura 76 – Distribuição dos valores da MMEP ao longo do processo de aprendizagem - Perfil 16

